

VYSOKÁ ŠKOLA BÁŇSKÁ – TECHNICKÁ UNIVERZITA OSTRAVA
EKONOMICKÁ FAKULTA

KATEDRA FINANČÍ

Predikce finanční tísně pomocí scoringového modelu

Prediction of Financial Distress Using a Scoring Model

Student: Bc. Aleš Trčka

Vedoucí diplomové práce: Ing. Martina Novotná, Ph.D.

Ostrava 2013

Zadání diplomové práce

Student: **Bc. Aleš Trčka**
Studijní program: **N6202 Hospodářská politika a správa**
Studijní obor: **6202T010 Finance**
Specializace: **00 Finance**
Téma: **Predikce finanční tísně pomocí scoringového modelu**
Prediction of Financial Distress Using a Scoring Model

Zásady pro vypracování:

1. Úvod
2. Charakteristika základních přístupů komplexního hodnocení podniků
3. Metodologie odhadu predikčních modelů
4. Aplikace vybraných metod a odhad predikčního modelu
5. Závěr

Seznam použité literatury

Seznam zkratk

Prohlášení o využití výsledků diplomové práce

Seznam příloh

Přílohy

Seznam doporučené odborné literatury:

HOSMER, David W. a Stanley LEMESHOW. *Applied logistic regression*. 2nd ed. New York: Wiley, 2000. 375 p. ISBN 0-471-35632-8.

LÖFFLER, Gunter a Peter N. POSCH. *Credit risk modeling using Excel and VBA*. 1st ed. Chichester: Wiley, 2007. 261 p. ISBN 978-0-470-03157-5.

VOCHOZKA, Marek. *Metody komplexního hodnocení podniku*. 1. vyd. Praha: Grada, 2011. 246 s. ISBN 978-80-247-3647-1.

Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

Vedoucí diplomové práce: **Ing. Martina Novotná, Ph.D.**

Datum zadání: 23.11.2012

Datum odevzdání: 26.04.2013

Ing. Iveta Ratmanová, Ph.D.
vedoucí katedry



prof. Dr. Ing. Dana Dluhošová
děkanka fakulty

Prohlašuji, že jsem celou diplomovou práci, včetně příloh, vypracoval samostatně.

V Ostravě 26. dubna 2013



.....

Bc. Aleš Trčka

Na tomto místě bych rád poděkoval Ing. Martině Novotné, Ph.D. za odborné rady a cenné připomínky, které přispěly k vypracování této diplomové práce.

Obsah:

1	Úvod	5
2	Charakteristika základních přístupů komplexního hodnocení podniků	6
2.1	Riziko úpadku a finanční tísně	6
2.2	Úpadek společnosti	7
2.3	Využití finanční analýzy	8
2.3.1	Zdroje finanční analýzy	8
2.3.2	Absolutní analýza	9
2.3.3	Poměrové ukazatele	10
2.4	Souhrnné modely hodnocení finančního zdraví	16
2.4.1	Bankrotní modely	17
2.4.2	Bonitní modely	21
3	Metodologie odhadu predikčních modelů	23
3.1	Východiska statistického usuzování	23
3.1.1	Základní charakteristiky vstupních dat	23
3.1.2	Multikolinearita	24
3.2	Skóringové modely	25
3.3	Regresní analýza	26
3.4	Diskriminační analýza	28
3.4.1	Stanovení cílů diskriminační analýzy	28
3.4.2	Formulace úlohy a volba jednotlivých znaků	29
3.4.3	Předpoklady diskriminační analýzy	29
3.4.4	Odhad diskriminační funkce	29
3.4.5	Interpretace výsledků	32
3.4.6	Ověření predikční síly	32
3.5	Logistická regrese	33
3.5.1	Stanovení cílů logistické regrese	34
3.5.2	Odhad logistického modelu	34
3.5.3	Ověření správnosti modelu	36
3.5.4	Interpretace výsledků	37
3.5.5	Ověření predikční síly	38
4	Aplikace vybraných metod a odhad predikčního modelu	41
4.1	Popis vstupních dat	41

4.2	Diskriminační analýza	43
4.2.1	Multikolinearita	43
4.2.2	Popisná statistika	43
4.2.3	Kroková metoda	44
4.2.4	Odvození diskriminační funkce	46
4.2.5	Výpočet prahového bodu	48
4.2.6	Klasifikační matice analyzovaného vzorku dat.....	48
4.2.7	Klasifikační matice klasifikovaného vzorku dat	50
4.2.8	Fisherova diskriminační funkce	52
4.3	Logistická regrese.....	54
4.3.1	Vysvětlované a vysvětlující proměnné	54
4.3.2	Multikolinearita.....	55
4.3.3	Kroková metoda	55
4.3.4	Odhad logistického modelu.....	57
4.3.5	Ověření správnosti modelu.....	57
4.3.6	Poměr šancí (odds ratio).....	58
4.3.7	Klasifikační matice analyzovaného vzorku dat.....	59
4.3.8	Klasifikační matice klasifikovaného vzorku dat	62
4.3.9	Klasifikační schopnost při zavedení šedé zóny	64
4.4	Srovnání vytvořených modelů.....	65
5	Závěr	66
	Seznam použité literatury	68
	Seznam zkratk	72
	Prohlášení o využití výsledků diplomové práce	
	Seznam příloh	

1 Úvod

Znalost finančního zdraví obchodního partnera, nebo potencionálního dlužníka je v dnešní době rozvinutých dodavatelsko-odběratelských vztahů velmi důležitá. Z důvodu bankrotu obchodního partnera se může věřitel dostat bez svého zavinění do druhotné platební neschopnosti. K rychlému ověření finančního zdraví lze využít predikčních modelů. Účelem predikčních modelů je na základě charakteristických znaků signalizovat možnost vzniku určitého negativního jevu a tím eliminovat případné škody. V souvislosti s predikčními modely je však potřeba si uvědomit, že se na tyto modely nelze spoléhat stoprocentně, ale je potřeba je využívat spolu s dalšími metodami a postupy.

Cílem této diplomové práce je odhad modelů predikce finanční tísně pomocí aplikace vybraných vícerozměrných statistických metod. Jednotlivé modely jsou odhadnuty na základě finanční analýzy 429 českých obchodních společností využitím metody diskriminační analýzy a logistické regrese.

Diplomová práce je členěna do pěti kapitol. Kapitulu první tvoří úvod, pátou pak závěr diplomové práce. Teoretickou část tvoří kapitola druhá a třetí. V kapitole druhé jsou popsány jednotlivé základní přístupy komplexního hodnocení podniků. První část kapitoly je věnována deskripci finanční analýzy a charakterizaci jednotlivých poměrových ukazatelů z oblasti rentability, likvidity, aktivity, zadluženosti a stability. Druhá část kapitoly obsahuje popis jednotlivých souhrnných modelů sloužících k hodnocení finančního zdraví podniků.

Kapitola třetí je věnována metodologii odhadu predikčních modelů. Na začátku kapitoly jsou charakterizována východiska statistického usuzování a principy skóringových modelů. Následně jsou popsány metody regresní a diskriminační analýzy spolu s metodou logistické regrese.

Kapitola čtvrtá představuje praktickou část diplomové práce. Obsahem čtvrté kapitoly je aplikace teoretických přístupů na finanční výkazy společností za rok 2011. Cílem kapitoly je odvození modelů predikce finanční tísně na základě diskriminační analýzy a logistické regrese pro zařazení jednotlivých firem do bankrotní skupiny. V závěru kapitoly jsou odvozené modely zhodnoceny a srovnány pomocí dosažené predikční síly.

2 Charakteristika základních přístupů komplexního hodnocení podniků

Cílem druhé kapitoly diplomové práce je charakteristika a vymezení finanční tísně, popis a objasnění metod finanční analýzy a přehled souhrnných modelů hodnocení podniku.

2.1 Riziko úpadku a finanční tísně

Dle Smejkal (2010) neexistuje jedna jednoznačná definice rizika, která by byla obecně přijímána. Nejčastěji je pojem riziko vysvětlován jako pravděpodobnost, že dojde k události, jejímž následkem může dojít ke vzniku ztráty, odchýlení skutečných výsledků od výsledku očekávaných, nebo možnost úpadku podniku. Příčinou existence odchylky od očekávaného stavu je rizikový faktor, který může, nebo nemusí být danému subjektu podstupující riziko znám.

Dělení rizika

V rámci podnikatelské činnosti existují následující typy rizika:

- finanční,
- provozní,
- celkové.

Dle toho, na které subjekty riziko dopadá a zda posuzuje pozitivní i negativní dopad, lze členit dle následujících kategorií.

Čisté riziko je takové riziko, které je spojeno pouze s negativní stránkou. V případě čistého rizika se dá očekávat pouze existence ztráty, nebo neexistence ztráty. Čisté riziko je nečastěji spojeno se škodami a ztrátami organizací a jednotlivců, škodami způsobenými přírodními jevy a trestným jednáním lidí.

Podnikatelské riziko vyjadřuje hrozbu, že dosažené podnikatelské výsledky se budou lišit od výsledku očekávaných. Na rozdíl od rizika čistého počítá toto riziko i s pozitivní stránkou. Podnikatelské riziko tedy počítá jak s možným ziskem, tak s možnou ztrátou oproti očekávanému stavu.

Systematické riziko je způsobeno společnými faktory celkového ekonomického vývoje. Pro systematické riziko je charakteristický rys, že postihuje všechny subjekty. Jednotlivé podniky nejsou postihnuty stejně, totožně jsou však postihnuty podniky v určité oblasti podnikatelské činnosti. Faktory, které ovlivňují systematické riziko jsou dle Fotr

(2005) změny peněžní a rozpočtové politiky, změny v daňové oblasti, vývoj ekonomického cyklu, nebo celkové změny trhu. Systematické riziko nelze snižovat diverzifikací.

Nesystematická rizika jsou dle Fotr (2005) většinou rizika mikroekonomická. Pro nesystematické riziko je typické, že nedopadá na všechny podniky plošně, ale je specifické pouze pro jednotlivé firmy. Nejčastějším zdrojem nesystematického rizika jsou změny cen výrobních surovin, vznik nové konkurence na trhu, odchod klíčových zaměstnanců, nebo selhání výrobního zařízení.

2.2 Úpadek společnosti

Jako úpadek společnosti lze považovat situaci, kdy je u podniku ohrožena jeho budoucí existence v důsledku přetrvávajícího působení nežádoucích vlivů. Dle Synek (1996) lze za takové vlivy považovat nepříznivý vývoj výkonnostního potenciálu, pokles likvidity, tržní hodnoty nebo čistého obchodního jmění.

Legislativně je pojem úpadku v České republice řešen zákonem č. 182/2006 Sb., o úpadku a způsobech jeho řešení. Dle tohoto zákona je určeno, že dlužník se nachází v úpadku v případě, když:

- má více věřitelů a
- peněžité závazky jsou po lhůtě splatnosti delší než 30 dnů a
- není schopen závazky po lhůtě splatnosti plnit.

Jako podnik, který není schopen plnit své závazky je považován podnik, který:

- zastavil platby podstatné části svých peněžních závazků, nebo
- neplnil své závazky po dobu delší než 3 měsíce po lhůtě splatnosti, nebo
- není možné dosáhnout uspokojení splatných peněžních pohledávek výkonem rozhodnutí nebo exekucí, nebo
- nesplnil povinnost předložit seznamy, které mu uložil insolvenční správce.

Firma se nachází v úpadku v případě, že je předlužena. Situaci, kdy má podnik více věřitelů a celková výše závazku převyšuje souhrn jeho majetku, lze označit za předlužení. U společnosti se také dá předpokládat hrozící úpadek v případě, když s ohledem ke všem

skutečností nebude firma jako dlužník schopna včas a řádně plnit podstatnou část svých peněžitých závazků.

2.3 *Využití finanční analýzy*

V rámci této diplomové práce bude využita finanční analýza jako nástroj k získání indikátorů, na základě kterých budou následně vytvářeny modely predikce finanční tísně. Finanční analýza je významný prostředek pro rozklad finanční situace daného podniku a vyhodnocování zvolené strategie. Mimo hodnocení finanční pozice podniku slouží finanční analýza také pro mezipodnikové srovnání a hledání vhodných investičních příležitostí. Pomocí finanční analýzy lze hodnotit finanční minulost, současnost i predikovat předpokládaný budoucí vývoj.

Informace získané prostřednictvím finanční analýzy slouží pro různé skupiny, které s daným podnikem přicházejí do kontaktu. Subjekty lze rozdělit mezi interní a externí uživatele finanční analýzy. Jednotlivé skupiny přistupují k finanční analýze s různou mírou zájmu.

Externí uživatelé finanční analýzy jsou především investoři, bankovní instituce, stát, dodavatelé, odběratelé a konkurence. Tito uživatelé využívají zejména veřejně dostupné informace a data účetních výkazů, které mají povinnost podniky ze zákona zveřejňovat. Pomocí finanční analýzy hodnotí externí uživatelé především finanční zdraví podniku, návratnost investic, schopnost úhrady závazku, bonitu potencionálního dlužníka, nebo správné plnění daňové povinnosti.

Interní uživatelé finanční analýzy jsou manažeři, zaměstnanci a odboráři daného podniku. Zdrojem dat interních uživatelů jsou data vnitropodnikového, manažerského a finančního účetnictví. Cílem interní analýzy jsou podklady pro krátkodobé i dlouhodobé finanční řízení, zpětná vazba pro manažerské rozhodnutí, nebo informace pro zaměstnance z důvodu vazby vývoje mezd na hospodářský výsledek podniku.

2.3.1 *Zdroje finanční analýzy*

Hlavním podkladem pro aplikaci finanční analýzy jsou finanční informace daného podniku. Finanční informace jsou získávány především z vnitropodnikového účetnictví, výročních zpráv a zpráv finančních analytiků.

Mezi hlavní zdroj finančních informací patří **rozvaha**. Rozvaha je účetní výkaz, který informuje o výši majetku a zdrojů jeho financování k určitému časovému okamžiku. Rozvaha je tvořena na tzv. bilančním principu, kdy výše vykázaného majetku musí souhlasit s výši použitých zdrojů. Aktiva rozvahy jsou tvořena dlouhodobým majetkem a oběžnými aktivy. Pasiva tvoří vlastní zdroje a cizí kapitál.

Druhým významným zdrojem finanční analýzy je **výkaz zisku a ztráty**. Výkaz zisku a ztráty informuje o výši a způsobu tvorby hospodářského výsledku za určité účetní období. Výkaz zobrazuje veškeré náklady a výnosy podniku členěny dle oblasti činnosti v obdobích, se kterými věcně i časově souvisí.

Doplňkovým zdrojem finanční analýzy je **výkaz o peněžních tocích**. Úkolem výkazu je zobrazování peněžních toků za určité účetní období, se kterým věcně i časově souvisí. Výkaz o peněžních tocích je tvořen na bilančním principu, kdy se porovnávají příjmy podniku s jeho výdaji za provozní, investiční a finanční činnost.

Mezi jednotlivými účetními výkazy existují vazby. První vazba existuje mezi výkazem o peněžních tocích a rozvahou, kdy konečný stav peněžních prostředků z výkazu cash flow je zařazen mezi oběžná aktiva v rozvaze. Druhou vazbu lze sledovat mezi rozvahou a výkazem zisku a ztráty, kdy dosažený výsledek hospodaření ve výkazu zisku a ztráty je zařazen také mezi vlastní kapitál rozvahy.

2.3.2 Absolutní analýza

Absolutní analýza patří mezi nejjednodušší a nejrychlejší metody finanční analýzy, které slouží pro základní orientaci v systému analyzovaného podniku. Principem analýzy je procentní rozbor jednotlivých položek účetních výkazů. V rámci absolutní metody lze finanční výkazy analyzovat pomocí horizontálního a vertikálního rozboru.

Horizontální analýza zobrazuje, jak se určitá položka účetního výkazu změnila v čase. Změnu položky lze sledovat procentní změnou, bazickým, či řetězovým indexem. Horizontální analýza sleduje změny položek aktiv, pasiv a výkazu zisku a ztráty.

Prostřednictvím **vertikální analýzy** se sleduje, jak se určitá položka účetního výkazu podílí na zvoleném základu. Vertikální analýze jsou podrobovány položky aktiv, pasiv a výkazu zisku a ztráty. Při meziročním srovnání metoda zobrazuje procentní změnu dané položky, již však nedokáže určit příčinu této změny.

2.3.3 *Poměrové ukazatele*

Mezi nejčastěji využívané metody finanční analýzy patří poměrové ukazatele. Principem poměrových ukazatelů je hodnocení vztahu jednotlivých finančně-účetních informací. Hlavní důraz u poměrové analýzy je kladen na vypovídací schopnost jednotlivých ukazatelů a jejich způsob interpretace. V rámci finanční analýzy jsou sledovány oblasti:

- rentability,
- likvidity,
- aktivity,
- zadluženosti a stability.

Ukazatele rentability

Ukazatele rentability slouží k hodnocení návratnosti jednotlivých složek vloženého kapitálu. Rentabilita vyjadřuje, jak je schopen podnik dosahovat zisku prostřednictvím vloženého kapitálu. Obecně se u ukazatelů rentability poměruje určitý zisk s vloženým kapitálem, či tržbami. K výpočtu se využívají následující typy zisku:

- EBIT – zisk před úroky a zdaněním,
- EBT – zisk před zdaněním,
- EAT – čistý zisk.

Rentabilita aktiv je považována za hlavní měřítko hodnocení rentability, neboť slouží k hodnocení celkové efektivnosti analyzované firmy. U rentability aktiv se sledují veškerá aktiva bez ohledu na to, zda-li jsou financována kapitálem vlastním, nebo cizím. Rentabilitu aktiv lze vypočítat dle následujícího vzorce:

$$ROA = \frac{EBIT}{\text{celková aktiva}}. \quad (2.1)$$

Za optimální se považuje rostoucí trend ukazatele rentability aktiv.

Rentabilita vlastního kapitálu vyjadřuje schopnost výnosnosti kapitálu, který byl do analyzovaného podniku vložen vlastníky nebo akcionáři. Hlavní důraz je kladen na to, zda-li vložený kapitál dosahuje vyšší výnosnosti, než jaké riziko podstupují akcionáři. Výpočet rentability vlastního kapitálu lze vyjádřit dle následujícího vzorce:

$$ROE = \frac{EAT}{\text{vlastní kapitál}}. \quad (2.2)$$

Optimální je rostoucí trend ukazatele rentability vlastního kapitálu v čase. Důležité je, aby byl ukazatel vyšší než úroky získané při jiné formě investování. V opačném případě může docházet k situaci, že investoři nebudou do podniku investovat a bude docházet k odlivu kapitálu.

Rentabilita dlouhodobých zdrojů poměřuje zisk před úroky a zdaněním s dlouhodobě investovanými zdroji. Dlouhodobými zdroji se rozumí vlastní kapitál spolu s bankovními úvěry a emitovanými obligacemi. Ukazatel tedy pracuje s investovaným kapitálem bez ohledu na původ kapitálu. Rentabilita dlouhodobých zdrojů je využívána především kvůli mezipodnikovému srovnání. Ukazatel lze vypočítat dle následujícího vzorce:

$$ROCE = \frac{EBIT}{\text{vlastní kapitál} + \text{dlouhodobé závazky}}. \quad (2.3)$$

Pozitivně je hodnocen rostoucí trend ukazatele rentability dlouhodobých zdrojů v čase.

Rentabilita tržeb vyjadřuje podíl čistého zisku, který připadá na jednu jednotku tržeb. Neboli ukazatel říká, jak velký čistý zisk připadá na jednu korunu dosažených tržeb. Ukazatel lze vypočítat dle následujícího vzorce:

$$ROS = \frac{EAT}{\text{tržby}}. \quad (2.4)$$

Pozitivně je hodnocen rostoucí trend ukazatele rentability tržeb v čase. Pokud je potřeba vyjádřit rentabilitu tržeb bez vlivu zdanění, je vhodnější využít místo čistého zisku zisk před úroky a zdaněním. Rentabilita tržeb snížena o vliv zdanění je vhodná pro mezipodniková srovnání s rozdílným zdaněním jejich podnikatelské činnosti.

Rentabilita nákladů sleduje poměr dosaženého zisku k celkovým nákladům. Ukazatel vypovídá o tom, jak velký zisk je podnik schopen vytvořit při využití jedné koruny nákladů. Rentabilita nákladů se využívá především jako doplňkový ukazatel k ukazateli rentability tržeb. Rentabilitu nákladů lze vypočítat dle následujícího vzorce:

$$ROC = \frac{EAT}{\text{celkové náklady}}. \quad (2.5)$$

Vhodný je rostoucí trend ukazatele, což znamená zvyšování dosahovaného zisku při současném snižování celkových nákladů.

Ukazatele likvidity

Pojem likvidita vyjadřuje schopnost podniku v plné výši a v daném časovém okamžiku hradit své závazky. Jedná se tedy o rozbor platební schopnosti podniku. Pokud je podnik dlouhodobě nelikvidní, hovoříme o tzv. platební neschopnosti, která většinou vyústí v úpadek podniku. Současně však není vhodná velmi vysoká likvidita, neboť nejvíce likvidní aktiva jsou většinou spojena s nejmenší výnosností.

Ukazatel **celkové likvidity** je považován za likviditu třetího stupně. Pomocí ukazatele lze určit, kolikrát jsou krátkodobé závazky kryty oběžnými aktivy. Problémem ukazatele je nezohlednění schopnosti jednotlivých oběžných aktiv přeměny na pohotové peněžní prostředky. Celkovou likviditu lze vypočítat dle následujícího vzorce:

$$\text{celková likvidita} = \frac{\text{oběžná aktiva}}{\text{krátkodobé závazky}}. \quad (2.6)$$

Pozitivně je hodnoceno, pokud jsou krátkodobé závazky podniku kryty 1,5 až 2,5 krát objemem oběžných aktiv.

Pohotová likvidita vyjadřuje likviditu druhého stupně. Ukazatel sleduje schopnost podniku uhradit své aktuálně splatné závazky bez toho, aniž by musel prodávat své zásoby, které jsou důležité pro další výrobní činnost podniku. Pohotovou likviditu lze vypočítat dle následujícího vzorce:

$$\text{běžná likvidita} = \frac{\text{oběžná aktiva} - \text{zásoby}}{\text{krátkodobé závazky}}. \quad (2.7)$$

Optimální situace nastává v případě, pokud je podnik schopen 1 až 1,5 násobně krýt své krátkodobé závazky oběžnými aktivy, které jsou sníženy o zásoby.

Likviditu prvního stupně vyjadřuje **okamžitá likvidita**. Pomocí tohoto ukazatele se sleduje, v jakém poměru jsou krátkodobé závazky kryty pohotovými platebními prostředky. Mezi pohotové platební prostředky jsou zařazeny peníze v pokladně, peníze na běžném účtu, nebo volně obchodovatelné cenné papíry. Okamžitou likviditu lze vyjádřit dle následujícího vzorce:

$$\text{okamžitá likvidita} = \frac{\text{pohotové platební prostředky}}{\text{krátkodobé závazky}}. \quad (2.8)$$

Optimální hodnota ukazatele okamžité likvidity se pohybuje v pásmu od 0,9 do 1,1. Ukazatel

by měl být využíván především k dokreslení úrovně likvidity z důvodu vysoké nestability pohotových peněžních prostředků.

Ukazatele aktivity

Pomocí ukazatelů aktivity se hodnotí schopnost firem využívat svůj majetek a také vázanost kapitálu v jednotlivých položkách aktiv a pasiv. První sledovanou oblastí je obrátkovost, pomocí níž se sleduje počet obrátek aktiv za určité období. Druhou sledovanou oblastí je doba obratu, pomocí níž se hodnotí počet dní, které trvá jedna obrátka určitého aktiva či pasiva.

Obrátka celkových aktiv hodnotí schopnost firmy využívat celková aktiva k dosahování tržeb. Ukazatel slouží ke komplexnímu hodnocení efektivnosti využívání aktiv. Obrátku celkových aktiv lze vypočítat dle následujícího vzorce:

$$\text{obrátka celkových aktiv} = \frac{\text{tržby}}{\text{celková aktiva}}. \quad (2.9)$$

Optimální je růst ukazatele obrátky celkových aktiv v čase.

Doba obratu aktiv vyjadřuje počet dnů, za které dojde k obratu celkových aktiv v poměru k tržbám podniku. Výpočet doby obratu aktiv lze provést dle následujícího vzorce:

$$\text{doba obratu aktiv} = \frac{\text{celková aktiva} \cdot 360}{\text{tržby}}. \quad (2.10)$$

Pozitivně lze hodnotit klesající trend doby obratu aktiv.

Pomocí ukazatele **obratu zásob** lze hodnotit, kolikrát za rok je podnik schopen přeměnit zásoby na tržby. Ukazatel lze vypočítat dle následujícího vzorce:

$$\text{obrat zásob} = \frac{\text{tržby}}{\text{zásoby}}. \quad (2.11)$$

Doba obratu zásob znázorňuje počet dnů, po které jsou zásoby vázány ve výrobním procesu až do doby návratnosti ve formě tržeb. Dobu obratu zásob lze vyjádřit pomocí následujícího vzorce:

$$\text{doba obratu zásob} = \frac{\text{zásoby} \cdot 360}{\text{tržby}}. \quad (2.12)$$

Optimální je klesající trend ukazatele, což značí rychlejší změnu zásob zpět na peněžní prostředky.

Doba obratu pohledávek je ukazatel, který je důležitý pro plánování budoucích peněžních toků. Ukazatel sleduje strategii podniku při řízení pohledávek a udává dobu, za kterou jsou pohledávky přeměněny opět na peněžní prostředky. Ukazatel doby obratu pohledávek lze vyjádřit dle následujícího vzorce:

$$\text{doba obratu pohledávek} = \frac{\text{pohledávky} \cdot 360}{\text{tržby}}. \quad (2.13)$$

Pozitivně lze hodnotit klesající trend tohoto ukazatele v časovém horizontu. V případě dlouhodobě dosahovaných vysokých hodnot ukazatele doby obratu pohledávek je potřeba upravit dodavatelsko-odběratelské vztahy a s tím související platební kázeň odběratelů.

Ukazatel **doby obratu závazků** vyjadřuje počet dnů, za které by bylo možno splatit závazky podniku prostřednictvím dosažených tržeb. Doba obratu závazků lze vypočítat dle následujícího vztahu:

$$\text{doba obratu závazků} = \frac{\text{závazky} \cdot 360}{\text{tržby}}. \quad (2.14)$$

Optimální je stabilní vývoj doby obratu závazků v čase. Pro analyzovaný podnik je vhodné, aby doba obratu závazků byla delší než doba obratu pohledávek, čímž se snižuje pravděpodobnost vzniku tzv. druhotné platební neschopnosti.

Ukazatele zadluženosti a stability

Cílem ukazatelů zadluženosti a stability je hodnocení využívání finančních zdrojů daným podnikem. Pomocí těchto ukazatelů lze hodnotit zadluženost podniku, zapojení vlastních zdrojů, výši celkového kapitálu, nebo schopnost splácet náklady na získání cizího kapitálu.

Ukazatel **podílu vlastního kapitálu na aktivech** vyjadřuje, jak jsou celková aktiva podniku financována z vlastního kapitálu. Ukazatel lze vypočítat dle následujícího vzorce:

$$\text{podíl vlastního kapitálu na aktivech} = \frac{\text{vlastní kapitál}}{\text{aktiva celkem}}. \quad (2.15)$$

Vhodný je rostoucí trend tohoto ukazatele v čase. Hodnota ukazatele by však neměla být příliš vysoká, neboť se jedná o kapitál s nejvyššími náklady, který může snižovat výnosnost vložených prostředků.

Stupeň krytí stálých aktiv sleduje, jak jsou stálá aktiva financována dlouhodobými zdroji. U finančně zdravých firem by hodnota ukazatele měla být větší než 100 %, neboť dle zlatého bilančního pravidla by dlouhodobý majetek měl být financován z dlouhodobých zdrojů. Ukazatel lze vypočítat dle následujícího vzorce:

$$\text{stupeň krytí stálých aktiv} = \frac{\text{dlouhodobý kapitál}}{\text{stálá aktiva}}, \quad (2.16)$$

kde dlouhodobý kapitál je tvořen vlastním kapitálem a dlouhodobými cizími zdroji. Optimální je rostoucí trend ukazatele v čase.

Podíl stálých aktiv na celkových aktivech poměřuje velikost stálých aktiv na celkových aktivech. Vyšších hodnot lze dosáhnout u podniků, které se zabývají výrobní činností. Ukazatel lze vypočítat dle následujícího vzorce:

$$\text{podíl stálých aktiv na celkových aktivech} = \frac{\text{stálá aktiva}}{\text{celková aktiva}}. \quad (2.17)$$

Ukazatel **podílu oběžných aktiv na celkových aktivech** poměřuje podíl oběžných aktiv na aktivech celkových. Vyšších hodnot tohoto ukazatele lze zaznamenat u obchodních společností, které často vytvářejí vysoké zásoby. Ukazatel lze vypočítat dle následujícího vztahu:

$$\text{podíl oběžných aktiv na celkových aktivech} = \frac{\text{oběžná aktiva}}{\text{celková aktiva}}. \quad (2.18)$$

Pomocí ukazatele **celkové zadluženosti** lze hodnotit celkové podnikatelské riziko, které podstupují věřitelé podniku. Ukazatel poměřuje cizí zdroje s celkovými aktivy. Ukazatel celkové zadluženosti lze vyjádřit dle následujícího vzorce:

$$\text{celková zadluženost} = \frac{\text{cizí kapitál}}{\text{celková aktiva}}. \quad (2.19)$$

S rostoucí hodnotou celkové zadluženosti roste i velikost rizika, kterou podstupují věřitelé podniku. Optimální je klesající trend ukazatele v čase.

Ukazatel **dlouhodobé zadluženosti** poměřuje dlouhodobě vložený cizí kapitál s celkovými aktivy podniku. Za dlouhodobý vložený cizí kapitál jsou považovány rezervy, dlouhodobé závazky a dlouhodobé bankovní úvěry. Ukazatel lze vypočítat dle následujícího vztahu.

$$\text{dlouhodobá zadluženost} = \frac{\text{dlouhodobý cizí kapitál}}{\text{celková aktiva}}. \quad (2.20)$$

Pozitivně je hodnocen klesající trend tohoto ukazatele v čase.

Ukazatel **běžné zadluženosti** poměřuje krátkodobě vložený cizí kapitál do společnosti s celkovými aktivy. Ukazatel lze vypočítat dle následujícího vztahu:

$$\text{běžná zadluženost} = \frac{\text{krátkodobý cizí kapitál}}{\text{celková aktiva}}. \quad (2.21)$$

Vhodný je postupný klesající trend ukazatele běžné zadluženosti.

Ukazatel **úrokového zatížení** hodnotí, jak velká část vytvořeného zisku připadne na úhradu nákladových úroků. Ukazatel úrokového krytí lze vyjádřit dle následujícího vzorce:

$$\text{úrokové zatížení} = \frac{\text{nákladové úroky}}{EBIT}. \quad (2.22)$$

Vhodný je klesající trend tohoto ukazatele, který však musí být hodnocen v souvislosti s vývojem ukazatelů rentability a výnosnosti.

Velikost aktiv

Vzhledem k tomu, že jednotlivé obchodní společnosti disponují rozdílnou velikostí celkových aktiv, je vhodné transformovat tuto položku pro potřeby mezipodnikového srovnání. Hodnotu celkových aktiv lze transformovat pomocí logaritmu. Ukazatel je možno vypočítat dle následujícího vzorce:

$$\text{velikost aktiv} = \log(\text{celková aktiva}). \quad (2.23)$$

Čím vyšší hodnoty je dosaženo, tím vyšší je finanční stabilita analyzovaného podniku.

2.4 Souhrnné modely hodnocení finančního zdraví

Souhrnné modely slouží k hodnocení finanční situace firmy. Hlavní předností souhrnných modelů je vyjádření finanční situace podniku pomocí jednoho čísla. Prostřednictvím souhrnných modelů lze hodnotit finanční minulost, ale zároveň lze predikovat budoucí finanční vývoj daného podniku. Predikce budoucího finančního vývoje firmy slouží k určení, zda-li je podnik schopen i následujícího životaschopného vývoje. Dle Dluhošová (2008) je hlavním východiskem souhrnných modelů předpoklad, že u sledovaných podniků dochází k určitým odchylkám ve vývoji již několik let před samotným úpadkem,

kteřé jsou typické pro ohrožené podniky. Souhrnné modely hodnocení finančního zdraví lze rozčlenit na bankrotní a bonitní modely.

2.4.1 Bankrotní modely

Pomocí bankrotních modelů se dle Růčková (2008) určuje, zda podnik do určité doby zbankrotuje. Bankrotní modely fungují na principu, že u každého podniku ohroženého bankrotem se vyskytují signály, které jsou typické pro ohrožené podniky. Mezi takovéto signály patří zhoršený vývoj rentability celkového kapitálu, vývoj běžné likvidity, nebo výše čistého pracovního kapitálu. Mezi bankrotní modely patří následující modely:

- Altmanovo Z-skóre,
- Tafflerův model,
- model IN – index důvěřehodnosti,
- Beaverův model.

Altmanovo Z-skóre

Model Z-skóre publikoval Edward I. Altman v roce 1968. Pro predikci finanční tísně využil Altman aplikaci vícenásobné diskriminační analýzy na vzorek firem. Vzorek původního modelu se skládal z 66 společností. Jednu polovinu tvořily firmy, které se nacházely v konkurzu, druhou polovinu tvořily firmy, které se v konkurzu nenacházely. Ze vzorku byly eliminovány firmy, jejichž celková aktiva byla menší než jeden milion dolarů a zároveň velmi velké společnosti. U modelu bylo původně analyzováno 22 poměrových ukazatelů, které byly následně zredukovány na 6, které jsou nejvýznamnější pro predikci bankrotu.

Model Z-skóre byl publikován pro podniky veřejně obchodované na burze cenných papírů a pro ostatní obchodní společnosti. Z-skóre model pro podniky veřejně obchodovatelné na burze má následující tvar:

$$Z = 1,2X_1 + 1,4X_2 + 3,3X_3 + 0,6X_4 + 1,0X_5, \quad (2.24)$$

kde Z je celkové dosažené skóre, X_1 podíl pracovního kapitálu na celkových aktivech, X_2 rentabilita aktiv, X_3 podíl zisku před úroky a daněmi k celkovým aktivům, X_4 podíl tržní ceny aktiv k celkovým dluhům a X_5 podíl tržeb k celkovým aktivům.

Rozhodovacím kritériem, který určuje, zda-li je podnik před bankrotem či nikoliv je výsledek Z-skóre. Pokud je hodnota Z-skóre vyšší než 2,99, je velmi nízká pravděpodobnost bankrotu. Podniky, jejichž hodnota Z-skóre je nižší než 1,81, mají vysokou pravděpodobnost bankrotu díky zhoršené finanční situaci. Třetí oblast tvoří firmy, jejichž Z-skóre se nachází v intervalu od 1,81 do 2,99, jedná se o tzv. šedou zónu. U firem jejichž hodnota Z-skóre se nachází v šedé zóně nelze jednoznačně určit, zda budou v nejbližší době bankrotovat či nikoliv. Nejedná se tedy o firmy výrazně finančně zdravé, ale zároveň je nelze označit za firmy bankrotující.

Pro firmy, jejichž akcie nejsou obchodovány na burze, byl model modifikován a má následující tvar:

$$Z = 0,71X_1 + 0,85X_2 + 3,11X_3 + 0,42X_4 + 1,0X_5, \quad (2.25)$$

kdy jednotlivé proměnné mají stejný význam jako u modelu pro společnosti, které jsou veřejně obchodovatelné. Pokud je hodnota Z-skóre vyšší než 2,90, je u podniku minimální pravděpodobnost úpadku, hodnota nižší než 1,20 znamená vysokou pravděpodobnost bankrotu. Podniky, jejichž hodnota Z-skóre se nachází v intervalu od 1,20 do 2,90 se nacházejí v tzv. šedé zóně, u nichž nelze jednoznačně určit pravděpodobnost bankrotu.

Tafflerův model

Tafflerův model byl publikován v roce 1977 profesorem Richardem J. Tafflerem. Stejně jako u Altmanova Z-skóre byly využity ke konstrukci diskriminační funkce metody finančních poměrových ukazatelů. Model byl testován na vzorku firem, který se skládal ze 46 společností, které zbankrotovaly v letech 1968 až 1976. Tafflerův model existuje v základní a modifikované podobě. Základní tvar modelu má následující podobu:

$$Z_T = 0,53X_1 + 0,13X_2 + 3,18X_3 + 0,16X_4, \quad (2.26)$$

kde Z_T je celková dosažená hodnota, X_1 podíl zisku před zdaněním ke krátkodobým závazkům, X_2 oběžné aktiva k celkovým závazkům, X_3 podíl krátkodobých závazků k celkovým aktivům a X_4 podíl finančního majetku sníženého o krátkodobé dluhy a provozní náklady. Vysoká pravděpodobnost úpadku je v případech, že hodnota výsledku je nižší než 0. Pokud je hodnota výsledku vyšší než 0, pravděpodobnost úpadku je malá. V případě nedostatečných finančních zdrojů lze využít následující modifikovaný tvar modelu, který lze zapsat pomocí vzorce:

$$Z_T = 0,53X_1 + 0,13X_2 + 3,18X_3 + 0,16X_4, \quad (2.27)$$

kde proměnné X_1 až X_3 mají stejné vysvětlení jako u modelu základního a X_4 je poměr tržeb k celkovým aktivům. Pokud je výsledek menší než 0,2, je pravděpodobnost bankrotu vysoká. Při výsledku vyšším než 0,3 je pravděpodobnost bankrotu nízká.

Model IN – index důvěryhodnosti

Index důvěryhodnosti je index, který byl vytvořen manžely Neumaierovými. Cílem modelu bylo vyhodnocení finančního zdraví podniků vyskytujících se v českém prostředí. Dle Růčková (2010) se jedná o výsledek analýzy 24 významných matematicko-statistických ukazatelů podnikového hodnocení. Model IN pracuje s poměrovými ukazateli, konkrétně ukazateli rentability, likvidity, zadluženosti a aktivity. Model byl vytvořen na základě finančních analýz více než tisíce českých firem. Model zohledňuje také specifika jednotlivých oborů podnikání, neboť váha jednotlivých proměnných je přidělována dle odvětví. Model lze zapsat dle následujícího vzorce:

$$IN = V_1 \cdot X_1 + V_2 \cdot X_2 + V_3 \cdot X_3 + V_4 \cdot X_4 + V_5 \cdot X_5 + V_6 \cdot X_6, \quad (2.28)$$

kde V_n vyjadřuje váhu důležitosti daného kritéria podle odvětví podnikání, X_1 je podíl aktiv k cizímu kapitálu, X_2 podíl zisku před zdaněním a úroky k nákladovým úrokům, X_3 podíl zisku před zdaněním a úroky k celkovým aktivům, X_4 podíl tržeb k celkovým aktivům, X_5 podíl oběžných aktiv k součtu krátkodobých závazků a krátkodobým bankovním úvěrům a X_6 podíl závazků po lhůtě splatnosti k tržbám.

Pokud je hodnota indexu větší než 2, jedná se o podnik finančně zdravý bez existenčních problémů. V případě, že je hodnota indexu menší než 1, jedná se o firmu, která má problémy s finančním zdravím a zřejmě se v brzké době ocitne v existenčních problémech. Pokud se hodnota indexu IN nachází v intervalu 1 až 2, jedná se o firmu, která nemá přesně vyhraněné výsledky. Čím nižší je však hodnota indexu v daném intervalu, tím je pravděpodobnost potencionálního problému vyšší.

Index IN byl postupně revidován, kdy následně vznikl model IN99, který vyjadřuje tvorbu hodnoty pro vlastníka společnosti a IN01. Index důvěryhodnosti IN01 již v sobě spojuje bankrotní i bonitní model. Vzorek podniků byl rozdělen dle pravděpodobnosti bankrotu a dle tvorby přidané hodnoty EVA. Index IN05 je aktualizací indexu IN01, na které jsou aplikována data roku 2004. Index IN05 lze zapsat dle následujícího vzorce:

$$IN05 = 0,13X_1 + 0,04X_2 + 3,97X_3 + 0,21X_4 + 0,09X_5, \quad (2.29)$$

kde $IN05$ je výsledná hodnota indexu, X_1 podíl celkových aktiv a cizího kapitálu, X_2 podíl zisku před úroky a zdaněním a nákladovými úroky, X_3 podíl zisku před úroky a zdaněním a celkovými aktivy, X_4 podíl výnosů k celkovým aktivům a X_5 podíl oběžných aktiv a součtu krátkodobých závazků a krátkodobých bankovních úvěrů.

Pokud je hodnota indexu vyšší než 1,6, lze firmu označit za finančně zdravou. Firma nad touto hranicí dokáže také vytvářet přidanou ekonomickou hodnotu. Naopak v případě hodnoty indexu nižší než 0,9 firma nedokáže vytvářet přidanou ekonomickou hodnotu. Dosažená hodnota indexu v intervalu od 0,9 do 1,6 lze označit za tzv. šedou zónu. Firmy v šedé zóně mají pravděpodobnost 50%, že budou bankrotovat a 70%, že budou nadále tvořit přidanou hodnotu.

Beaverův model

Beaverův bankrotní model byl publikován v roce 1967 W. H. Beaverem. Cílem modelu byla analýza finančních problémů u firem pomocí poměrových ukazatelů finanční analýzy. Model byl vytvořen na základě finančních dat 158 firem, polovinu tvořily firmy, které neměly finanční problémy a druhou polovinu firmy, které zbankrotovaly. Dle Dluhošová (2008) zahrnul Beaver do svého modelu nejen společnosti, které skutečně zbankrotovaly, ale i společnosti, které vykazovaly znaky bankrotujících firem, čímž odstranil problém s definováním bankrotujících společností. Trendy, které jsou charakteristické pro jednotlivé poměrové ukazatele u ohrožených firem, shrnuje následující tabulka (Tab. 2.1).

Tab. 2.1 Parametry Beaverova modelu

Ukazatel	Trend u ohrožených firem
vlastní kapitál / celková aktiva	klesá
přidaná hodnota / aktiva celkem	klesá
bankovní úvěry / cizí zdroje	roste
cash flow / cizí zdroje	klesá
provozní kapitál / celková aktiva	klesá

Zdroj: Dluhošová (2008, str. 91)

Dle provedené analýzy bylo Beaverem zjištěno, že finanční problémy společností a následný bankrot lze pomocí poměrových ukazatelů predikovat již 5 let před samotným bankrotem společnosti.

2.4.2 Bonitní modely

Druhou skupinu tvoří bonitní modely. Předmětem bonitních modelů je dle Marinič (2008) zhodnocení předpokladů podniku, zda bude schopen dostat včas a v plné výši všem svým závazkům. Bonitní modely tedy určují především důvěryhodnost dlužníka. Pomocí bonitních modelů lze rozdělit firmy na dobré a špatné, proto je důležitá následná možnost srovnání s firmami v rámci určitého odvětví podnikání. Mezi bonitní modely lze zařadit:

- Index bonity,
- Kralickův Quicktest.

Index bonity

Index bonity je model vytvořený na základě vícerozměrné statistické diskriminační analýzy podle zjednodušené metody. Index je založen na sledování finanční a výkonnostní situace daného podniku skrze vybraných poměrových ukazatelů finanční analýzy. Index bonity se využívá především v německy mluvících zemích a lze vypočítat dle následujícího vzorce:

$$B_i = 1,5X_1 + 0,08X_2 + 10X_3 + 5X_4 + 0,3X_5 + 0,1X_6, \quad (2.30)$$

kde B_i vyjadřuje hodnotu indexu bonity, X_1 je podíl cash flow a cizích zdrojů, X_2 podíl celkových aktiv a cizích zdrojů, X_3 podíl zisku před zdaněním a celkových aktiv, X_4 podíl zisku před zdaněním a celkových výkonů, X_5 podíl zásob a celkových výkonů a X_6 podíl celkových výkonů k celkovým aktivům.

Čím vyšší je dosažená hodnota indexu bonity, tím vyšší je finančně-ekonomická situace hodnoceného podniku (Sedláček, 2001). Konkrétní stupnici indexu zobrazuje následující tabulka (Tab. 2.2).

Tab. 2.2 Stupnice indexu bonity

Hodnota indexu	<-3;-2>	<-2;-1>	<-1;0 >	<0;1>	<1;2>	<2;3>	<3+>
Finanční stav	extremně špatná	velmi špatná	špatná	určité problémy	dobrá	velmi dobrá	extrémně dobrá

Zdroj: Sedláček (2001, str. 128)

Kralickův Quicktest

Jedná se o bonitní model, který se skládá ze soustavy čtyř rovnic, podle jejichž výsledku se firmě přidělují body. Celkové výsledné hodnocení Quicktestu vznikne jako

vážený průměr jednotlivých rovnic. Pomocí Kralickova Quicktestu lze hodnotit celkovou bonitu, či samostatně finanční stabilitu a finanční situaci podniku. Kralickýv Quicktest se skládá z následujících rovnic:

$$R_1 = \frac{\text{vlastní kapitál}}{\text{aktiva celkem}}, \quad (2.31)$$

$$R_2 = \frac{(\text{cizí zdroje} - \text{peníze} - \text{účty u bank})}{\text{provozní cash flow}}, \quad (2.32)$$

$$R_3 = \frac{EBIT}{\text{aktiva celkem}}, \quad (2.33)$$

$$R_4 = \frac{\text{provozní cash flow}}{\text{výkony}}. \quad (2.34)$$

Body, které jsou přidělovány dle výsledků jednotlivých rovnic zobrazuje níže uvedená tabulka (Tab. 2.3). Finanční stabilitu lze vypočítat pomocí součtu rovnic R_1 a R_2 , které vydělíme hodnotou 2. Finanční situaci podniku lze vypočítat pomocí součtu rovnic R_3 a R_4 , kterou opět vydělíme hodnotou 2. Celková hodnota Kralickova Quicktestu je získána jako suma hodnoty finanční stability a hodnoty finanční situace, která je vydělena hodnotou 2.

Tab. 2.3 Bodování výsledků Kralickova Quicktestu

	0 bodů	1 bod	2 body	3 body	4 body
R₁	< 0	0 – 0,1	0,1 – 0,2	0,2 – 0,3	> 0,3
R₂	< 3	3 – 5	5 – 12	12 – 30	> 30
R₃	< 0	0 – 0,08	0,08 – 0,12	0,12 – 0,15	> 0,15
R₄	< 0	0 – 0,05	0,05 – 0,08	0,08 – 0,1	> 0,1

Zdroj: Růčková (2010, str. 81)

V případě výsledné hodnoty testu vyšší než 3 se považuje firma za bonitní, naopak hodnota menší než jedna vyjadřuje finanční potíže a ohrožení bonity. Dosažení bodového hodnocení v intervalu od 1 do 3 vyjadřuje tzv. šedou zónu, kdy nelze jednoznačně určit bonitu, či finanční potíže společnosti.

3 Metodologie odhadu predikčních modelů

Cílem třetí kapitoly je popis jednotlivých metod, které slouží ke konstrukci predikčních modelů. V první části budou popsány základní statistické charakteristiky, které jsou využívány při tvorbě modelů. Následně bude charakterizována metoda regresní a diskriminační analýzy. V závěru kapitoly je popsána metoda logistické regrese a nástroje k ověření predikční schopnosti jednotlivých modelů.

3.1 Výhodiska statistického usuzování

Hlavním předpokladem pro tvorbu predikčních modelů je využití statistických nástrojů. Statistika je vědní obor, který pomocí vizuálních a numerických nástrojů umožňuje zobrazovat a analyzovat data. Dle Rost (2011) lze v rámci vícerozměrné analýzy dat rozlišovat mezi metodou:

- konfirmační,
- explorační.

Konfirmační metoda využívá především intervalové spolehlivosti a regresní analýzu. Hlavními nástroji explorační metody je metoda hlavních komponent, shluková a faktorová analýza.

3.1.1 Základní charakteristiky vstupních dat

Soubor, který je množinou všech prvků, jenž je možno v dané situaci zvažovat, se nazývá **základní soubor**. Jedná se tedy o všechny prvky, které mohou vstupovat do výběrového souboru. Z finančních, časových a etických důvodů není často možné pracovat s celým základním souborem. Proto se využívá pouze podmnožina základního souboru, která se nazývá **výběr**. Hlavní charakteristikou je počet prvků ve výběru, který je nazýván **rozsahem výběru**.

K charakterizaci jednotlivých prvků základního souboru slouží proměnné. Dle Hendl (2009) mohou proměnné nabývat více hodnot a existuje pro ně předpis, jak tyto hodnoty lze zjistit. Aktuální hodnoty jednotlivých proměnných jsou tvořeny daty. Rozlišujeme tři základní typy proměnných. Jedná se o:

- závislé proměnné,
- nezávislé proměnné,

- rušivé proměnné.

Závislé proměnné, neboli cílové, jsou proměnné, jejichž vývoj je popisován nezávisle proměnnými. Jedná se tedy o výsledek působení vysvětlujících proměnných. **Nezávislé proměnné**, neboli prediktory, jsou proměnné, které vysvětlují vývoj závislé proměnné. V důsledku změn nezávisle proměnných se mění i závislé proměnné. Jedná se tedy o statistickou závislost, neboť dochází k systematickému pohybu jedné veličiny při růstu, nebo poklesu veličiny druhé. **Rušivé proměnné** představují takové proměnné, která mají vztah s cílovou proměnnou. Působení rušivé proměnné může způsobovat nepřesné uvažování o vztahu mezi závislými a nezávislými proměnnými.

K určení charakteristických hodnot souboru slouží nástroje míry centrální tendence. Základní metodou míry centrální tendence je **střední hodnota**. Střední hodnota vyjadřuje součet jednotlivých dat výběru, které jsou děleny počtem dat. Pro výběr je možno vypočítat střední hodnotu pomocí následujícího vzorce:

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i = \frac{x_1 + x_2 + x_3 + \dots + x_n}{n}, \quad (3.1)$$

kde x_i jsou jednotlivé prvky výběru a n je počet prvku ve výběru. Obdobně je možno vypočítat střední hodnotu pro celý základní soubor.

Dalším nástrojem je **modus**, který představuje takovou hodnotu, kdy 50 % dat v souboru je větších než tato hodnota a naopak 50 % dat je menší než tato hodnota. Posledním základním nástrojem míry centrální tendence je **medián**, znázorňující hodnotu, která se v základním souboru nebo výběru vyskytuje nejčastěji.

3.1.2 *Multikolinearita*

Pojem multikolinearita znamená, že mezi pozorovanými vysvětlujícími proměnnými se vyskytuje lineární závislost. Podstatou měření multikolinearity je zkoumání intenzity této závislosti. Dle Hančlová (2012), jsou hlavními příčinami existence multikolinearity:

- stejná trendová tendence časových řad,
- neexperimentální charakter disponibilních dat při průřezové analýze,
- nevhodné zavedení zpožděných vysvětlujících proměnných,
- neadekvátní použití umělých proměnných.

K měření multikolinearity mezi vysvětlujícími proměnnými se využívá párová korelace. Výpočet párové korelace je možno znázornit pomocí následujícího vzorce:

$$r_{x_1x_2} = \frac{\text{cov}(x_1x_2)}{s_{x_1} s_{x_2}} \in \langle -1; 1 \rangle, \quad (3.2)$$

kde x_n jsou jednotlivé proměnné, cov je kovariance dvou proměnných a s_x je rozptyl proměnných. Pokud je hodnota párové korelace vyšší než 0,8, existuje mezi vysvětlujícími proměnnými silná lineární závislost. Možností odstranění multikolinearity je vyjmutí vysvětlující proměnné z modelování, získání nového výběru, použití metody hlavních komponent, nebo transformace proměnných.

3.2 Skóringové modely

Významným nástrojem pro určování kreditního rizika a predikci finanční tísně jsou skóringové modely. Nejčastěji se tyto modely využívají v pojišťovnictví a bankovníctví, kde slouží k určení rizika, které je spojeno s určitými klienty, či produkty. Účelem skóringových modelů je určení, zda-li je s daným subjektem kreditní riziko spojeno či nikoliv. Jednotlivé skóringové modely se vytvářejí na základě historických dat, které se následně srovnávají se získanými daty např. od žadatelů o úvěr. Mezi hlavní výhodu skóringových modelů patří srovnávání stejných kritérií u jednotlivých subjektů, čímž se zamezuje subjektivnímu posuzování. Naopak mezi nevýhody patří předpoklad stejného nebo velmi podobného chování jednotlivých subjektů.

Pomocí skóringových modelů lze vytvořit skóringovou funkci, která jednotlivým subjektům přiděluje skóre na základě jejich jednotlivých charakteristik. Mezi takové charakteristiky patří účetní výkazy, osobní údaje u fyzických osob, nebo transakční historie. Pomocí dosaženého skóre lze následně analyzované subjekty přidělit např. do bankrotní skupiny. Mezi hlavní statistické nástroje, které slouží k tvorbě skóringových predikčních modelů patří:

- regresní analýza,
- diskriminační analýza,
- logistická regrese.

3.3 Regresní analýza

Regresní analýza slouží k odhalování a hodnocení vzájemné závislosti mezi vysvětlujícími a vysvětlovanými proměnnými. Význam pojmu regrese spočívá v systematických změnách, které jsou způsobovány u jedné proměnné v důsledku působení změn u proměnných jiných.

Regresní analýza se využívá především z důvodu, že na vysvětlovanou proměnnou nepůsobí většinou pouze jedna náhodná veličina, tak jak je tomu u funkčního vztahu. V případě regresní analýzy se jedná o stochastický vztah mezi jednotlivými veličinami. O stochasticky závislé veličiny se jedná v případě, kdy změna jedné náhodné veličiny způsobí změnu rozdělení pravděpodobnosti u druhé náhodné veličiny. Typickým rysem stochastických veličin jsou:

- změny závislé proměnné nemusí být vysvětlovány změnou všech nezávislých proměnných, ale pouze některými,
- zohledňování působení náhodných vlivů,
- připuštění možnosti chyb při zjišťování údajů.

Stochastická závislost se projevuje ve změnách středních hodnot. Změna středních hodnot u jedné náhodné veličiny vyvolá změnu hodnoty také u druhé náhodné veličiny. Tuto závislost lze popsat pomocí regresní funkce, prostřednictvím které je možno předpovídat, jaké hodnoty bude jedna náhodná veličina dosahovat při změně druhé náhodné veličiny. Regresní funkci je možno zapsat jako podmíněnou střední hodnotu veličiny Y [$E(Y|x)$] ve vztahu k různým lineárním kombinacím jiných náhodných proměnných a má následující tvar:

$$E(Y|x) = g(x, \beta_0, \beta_1, \beta_2, \dots, \beta_k), \quad (3.3)$$

kde g je funkce proměnné x a β_n jsou jednotlivé regresní koeficienty. Dle Kubánová (2003), lze rozlišovat tři základní typy regresních modelů. Podle tvaru regresní funkce můžeme regresní modely rozdělit na:

- lineární modely,
- nelineární modely,
- nelineární modely, které se nedají transformovat na modely lineární.

Model se považuje za **lineární** v případě, že tvar regresní funkce má podobu přímky, paraboly, hyperboly nebo roviny. Dalším typem jsou **nelineární modely**. Tyto modely lze vzhledem k jejich parametrům transformovat na modely lineární, a to pomocí regresní mocninné a exponenciální funkce. U lineárních a nelineárních modelů, které lze na modely lineární transformovat se k odhadu parametrů nejčastěji využívá metoda nejmenších čtverců. Posledním typem jsou **nelineární modely, které nelze jednoduše převést na modely lineární**. V tomto případě není vhodné využít k odhadu jednotlivých parametrů metodu nejmenších čtverců, ale je potřeba aplikovat např. metodu dílčích průměrů, částečných součtů, nebo vybraných bodů.

Lineární model

V rámci lineárního modelu rozlišujeme model obecný (deterministický) a stochastický. Rozdíl mezi oběma typy modelů spočívá v reziduální složce. Model deterministický je možno zapsat následovně:

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_n x_n, \quad (3.4)$$

kde Y je vysvětlovaná proměnná, β_n jsou regresní koeficienty a x_n jsou vysvětlující proměnné. Jak je z rovnice patrné, není zde obsažena žádná náhodná (reziduální) složka. Při znalosti jednotlivých hodnot je možno jednoduše vypočítat regresní závislost mezi vysvětlovanou a vysvětlujícími proměnnými. Přidáním reziduální složky do modelu získáme zcela lineární (stochastický) model. Tento model má následující podobu:

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_n x_n + \varepsilon_i, \quad (3.5)$$

kde ε zobrazuje náhodnou složku modelu. Účelem náhodné složky je zahrnutí všech náhodných vlivů, které nejsou v modelu zahrnuty prostřednictvím jednotlivých proměnných. Jednotlivé dílčí regresní koeficienty vyjadřují, jak daná proměnná přispívá k vývoji vysvětlující proměnné. Model obecný i model stochastický lze souhrnně nazvat jako **klasický lineární model**. Tvar klasického lineárního modelu lze zobrazit následujícím vztahem:

$$Y = X\beta + \varepsilon, \quad (3.6)$$

kde X je matice zadaných hodnot vysvětlujících proměnných. Aby se skutečně jednalo o klasický lineární model, musí být dle Briš (2004) splněny následující podmínky:

- $E(\varepsilon_i) = 0$ pro každé $i = 1, 2, \dots, n$. Střední hodnota náhodné složky je nulová. To znamená, že náhodná složka nepůsobí systematickým způsobem na hodnoty vysvětlované proměnné,

- $D(\varepsilon_i) = \sigma^2$ pro každé $i=1,2,\dots,n$. Rozptyl náhodné složky je konstantní. Variabilita náhodné složky nezávisí na hodnotách vysvětlujících proměnných,
- $\text{cov}(\varepsilon_i, \varepsilon_j) = 0$ pro každé $i \neq j$, kde $i, j = 1, 2, \dots, n$. Kovariance náhodné složky je nulová,
- X je nenáhodná matice, z čehož vyplývá, že vysvětlující proměnné jsou nenáhodné,
- parametry β_j , $j=1,2,3,\dots,n$ mohou nabývat libovolných hodnot, neexistují tedy žádné omezující podmínky,
- matice X má plnou hodnost, $h(X)=k$ a dále $n > k$, kde n je počet pozorování. Mezi vysvětlujícími proměnnými nesmí existovat funkční lineární závislost,
- ε_i mají normální rozdělení pravděpodobnosti pro každé $i=1,2,\dots,n$, z čehož vyplývá normalita pro vysvětlovanou proměnnou.

3.4 Diskriminační analýza

Metoda diskriminační analýzy byla publikována v roce 1936 Ronaldem Fisherem. Tuto analýzu je možno zařadit mezi metodu lineárního modelování. Metoda je využívána především pro určení rozdílů mezi určitými skupinami objektů a pro zařazení nových objektů do existujících skupin.

Podstatou diskriminační analýzy je zkoumání závislosti mezi závislou proměnnou a jednotlivými nezávislými proměnnými (diskriminátory). Pomocí diskriminační analýzy lze určit pravidlo, dle kterého se jednotlivé znaky přiřazují do předem definovaných skupin.

3.4.1 Stanovení cílů diskriminační analýzy

V rámci prvního kroku diskriminační analýzy je potřeba stanovit základní cíle diskriminační analýzy. Hlavním cílem diskriminační analýzy je především správné zařazení objektů do jednotlivých tříd. Mezi dílčí cíle diskriminační analýzy patří zjištění, zda-li se mezi předem definovanými třídami nachází statisticky významné rozdíly. Mezi další dílčí cíle lze taky zařadit nalezení znaků, které nejvíce přispívají k rozdílnosti jednotlivých skupin, stanovení postupu k zařazování objektů na základě skóre a určení počtu a složení jednotlivých tříd.

3.4.2 *Formulace úlohy a volba jednotlivých znaků*

Druhým krokem diskriminační analýzy je formulace úlohy a volba jednotlivých znaků. Formulace úlohy spočívá především v určení závislých a nezávislých proměnných. Závislá proměnná bývá většinou kategorická, což znamená, že jí není možno měřit, ale pouze zařadit do určitých tříd. V případě dvou skupin se jedná o dichotomickou proměnnou, v případě více možných skupin se jedná o multichomickou proměnnou. Jednotlivé nezávislé proměnné jsou vyjádřeny v metrickém měřítku.

V rámci formulace úlohy je také potřeba určit velikost výběru, který slouží k odhadu diskriminační funkce. Velikost výběru je důležitá především z důvodu, že diskriminační analýza je poměrně citlivá na velikost jednotlivých skupin. Dle empirické úmluvy by měl být dodržen poměr 20 objektů na jeden znak, podle minimální velikosti výběru by měl poměr znaků na jeden objekt odpovídat 5. Celkový výběr lze také rozdělit na dva soubory, jedná se o tzv. analyzovaný a klasifikovaný výběr. Analyzovaný výběr slouží k vytvoření diskriminační funkce, klasifikovaný pak k následnému testování diskriminační funkce.

3.4.3 *Předpoklady diskriminační analýzy*

Pro správné odvození diskriminační funkce by měla být dodržena vícerozměrná normalita znaků, kovarianční matice by měly být stejné, výběr by neměl být příliš malý a mezi jednotlivými proměnnými by se neměla vyskytovat multikolinearita.

3.4.4 *Odhad diskriminační funkce*

Po provedení předchozích kroků může být přistoupeno k odhadu diskriminační funkce. K odhadu diskriminační funkce může být využito přímé (enter) nebo krokové metody (stepwise).

Podstatou **přímé metody** je vytvoření diskriminační funkce na základě všech dostupných nezávisle proměnných, bez ohledu na to, jakou diskriminační silou jednotlivé proměnné disponují. Druhou možností je využití **krokové metody**. Principem krokové metody je postupné zařazování i vyřazování jednotlivých nezávisle proměnných. První do modelu vždy vstupují nezávislé proměnné s největším vlivem na vysvětlovanou proměnnou. Dle Meloun (2004), je vybírání jednotlivých znaků ukončeno v případě, že žádné další znaky již nesplňují zaváděcí, či odstraňovací kritérium.

Rozhodovacím kritériem pro zařazení jednotlivých znaků do diskriminační funkce je **Wilksova lambda**. Dle Meloun (2004) představuje Wilksova lambda poměr sumy čtverců mezi třídami a celkového součtu čtverců. Do modelu je přidán ten prvek, jehož Wilksova lambda dosahuje nejnižší hodnoty. Kritérium lze vypočítat dle následujícího vzorce:

$$\lambda = \frac{\det W}{\det T} = \frac{\det W}{\det (W + B)}, \quad (3.7)$$

kde \det značí determinant, W je matice variability uvnitř tříd, T kovarianční matice, B součet matic mezitřídní variability. Při perfektní diskriminaci je hodnota λ rovna 0, při nevýznamné diskriminaci se jedná o hodnotu 1. Po přidávání jednotlivých znaků je potřeba provádět F-test. Pomocí F-testu se hodnotí významnost každého přidávaného znaku.

Dalším kritériem pro zařazení jednotlivých znaků je **míra tolerance**. Míra tolerance měří stupeň lineární závislosti mezi jednotlivými znaky. Nízká hodnota tohoto kritéria vyjadřuje, že určitý znak je lineární kombinací ostatních znaků, a tudíž nemůže být do diskriminační funkce zařazen.


Výsledkem výběru jednotlivých diskriminantů je odvození diskriminační rovnice, pomocí které lze vypočítat Z-skóre. Obecně lze diskriminační rovnici zapsat následujícím vztahem:

$$Z_i = a + b_1 x_1 + b_2 x_2 + \dots + b_n x_n, \quad (3.8)$$

kde Z_i je dosažené Z-skóre, a úrovněová konstanta, b_n diskriminační koeficienty a x_n vysvětlující proměnné.

Po odvození diskriminační rovnice a výpočtu jednotlivých Z-skóre je následujícím důležitým krokem výpočet prahového bodu. Na základě prahového bodu je možno určit, do které diskriminační skupiny bude určitý prvek zařazen. Podle poměru zastoupení jednotlivých prvků ve výběrovém souboru rozlišujeme dva základní typy prahového bodu. V případě, že poměrové zastoupení prvků jednotlivých skupin ve výběru je stejné, je možno využít **nevážený prahový bod**. Následující obrázek (Obr. 3.1) zobrazuje prahový bod v případě dvou stejně velkých skupin.

Obr. 3.1 Nevážený prahový bod




Zdroj: Meloun (2004)

Z obrázku je zjevné, že prahový bod (C) je průměr středních hodnot jednotlivých skupin. Zvýrazněná část v obrázku vyjadřuje pravděpodobnost chybné klasifikace, přerušovanou čarou jsou znázorněny centroidy. Výpočet neváženého prahového bodu je možno znázornit dle následujícího vztahu:

$$PB = \frac{C_A + C_B}{2}, \quad (3.9)$$

kde PB je výsledná hodnota prahového bodu, C_A centroid skupiny A, C_B centroid skupiny B. V případě, že velikost jednotlivých skupin je nestejná, je vhodnější pro přesnější klasifikaci **využít vážený prahový bod**. Vážený prahový bod znázorňuje následující obrázek (Obr. 3.2).

Obr. 3.2 Vážený prahový bod



Zdroj: Meloun (2004)

Dle obrázku (Obr. 3.2) je patrné, že v případě využití neváženého prahového bodu by došlo k výraznému zhoršení klasifikační schopnosti. Pro výpočet váženého prahového bodu slouží následující vzorec:

$$PB = \frac{C_A \cdot N_A + C_B N_B}{N_A + N_B}, \quad (3.10)$$

kde N_A a N_B je počet jednotlivých prvků v dané skupině. Pokud je tedy dosažené skóre dle diskriminační rovnice větší než hodnota prahového bodu, je prvek zařazen do skupiny B. Pokud je dosažené skóre naopak menší než hodnota prahového bodu, je daný prvek zařazen do skupiny A. Výsledné zařazení jednotlivých prvků lze znázornit pomocí klasifikační matice, která je uvedena v kapitole 3.5.5.

3.4.5 Interpretace výsledků

Významným krokem po odhadu jednotlivých koeficientů je jejich interpretace. Jednotlivé standardizované diskriminační koeficienty lze charakterizovat podle dosažené hodnoty a znaménka. Čím vyšší je dosažená hodnota diskriminačního koeficientu, tím vyšším vlivem působí daný koeficient na diskriminační sílu a naopak. Obdobně lze hodnotit koeficienty dle znaménka, kdy plus kladně přispívá k diskriminační síle a mínus naopak negativně.

3.4.6 Ověření predikční síly

Po vytvoření diskriminační rovnice a zařazení jednotlivých prvků do klasifikační matice je potřeba ověřit, zda-li je dosažena dostatečná klasifikační síla a model je tudíž vhodný pro následnou predikci. K ověření klasifikační schopnosti je možno využít Pressovu q-statistiku nebo tzv. hit poměr.

Pomocí **Pressovy q-statistiky** diskriminační síly se hodnotí, zda-li je klasifikační síla vytvořené diskriminační funkce dostatečná. Vypočtená hodnota se srovnává s kritickou hodnotou chi-kvadrátu. Q-statistiku můžeme vypočítat dle následujícího vzorce:

$$q = \frac{(n - n_s k)^2}{n(k-1)}, \quad (3.11)$$

kde n je počet prvků ve výběru, n_s počet správně zařazených prvků a k je počet klasifikačních skupin. Pokud je dosažená hodnota q-statistiky vyšší než hodnota chi-kvadrátu na dané hladině pravděpodobnosti, lze považovat klasifikační sílu za dostatečnou.

Hit poměr se využívá k hodnocení, jak daná diskriminační funkce dokáže zařazovat jednotlivé objekty. Hit poměr lze sledovat pro stejné třídní velikosti a pro nesterétné třídní velikosti jako kritérium maximální věrohodnosti a jako kritérium poměrné pravděpodobnosti.

Prvním případem jsou **stejně třídní velikosti**, kdy se minimálně požadovaná klasifikační schopnost rovná hodnotě poměru jednotlivých tříd. V případě 2 tříd se minimální požadovaná klasifikační síla rovná 0,5, v případě 3 tříd se tato hodnota rovná 0,33 apod.

V případě **nestejně velkých skupin** lze využít metodu kritéria maximální věrohodnosti. Při této metodě se skutečně dosažená klasifikační schopnost porovnává s poměrovým zastoupením největší skupiny na celkovém počtu prvků daného výběru. Pokud je skutečná klasifikační schopnost vyšší než minimálně požadovaná, lze klasifikační schopnost dané diskriminační rovnice považovat za dostatečnou. Hit poměr lze vypočítat dle následujícího vzorce:

$$h = (n_m / n) \cdot 100, \quad (3.12)$$

kde h je hit poměr, n_m počet prvků nejpočetnější skupiny a n počet prvků ve výběru.

Poslední metodou hit poměru je **kritérium poměrové pravděpodobnosti**. Tato metoda se využívá pro výběr dat, kdy jednotlivé skupiny jsou velikostně nesourodé. Kritérium poměrové pravděpodobnosti lze vypočítat dle následujícího vzorce:

$$\pi = p^2 + (1-p)^2, \quad (3.13)$$

kde p^2 je počet prvků skupiny A a $(1-p)^2$ je počet prvků ve skupině B. Diskriminační sílu lze považovat za dostatečnou, pokud je vypočtená (minimálně požadovaná) hodnota dle kritéria poměrové pravděpodobnosti nižší než skutečně dosažená klasifikační síla vytvořené diskriminační funkce.

3.5 *Logistická regrese*

Metoda logistické regrese byla publikována v 60. letech 20. století jako alternativní postup k metodě nejmenších čtverců. Metoda nalézá své uplatnění v oblasti ekonomie, marketingu, bankovníctví, technických a přírodních vědách.

Jedná se o speciální formu regresní analýzy. Podstatou logistické regrese je zkoumání vztahu mezi vysvětlovanou (závislou) proměnnou a vysvětlujícími (nezávislými) proměnnými. Na rozdíl od lineární regrese se však nepracuje se spojitou, ale s kategoričnou závisle proměnnou. Pomocí závislé proměnné lze poté určit existenci či neexistenci určitého jevu. Podobně jako v případě diskriminační analýzy lze postup shrnout do základních kroků.

3.5.1 Stanovení cílů logistické regrese

Prvním krokem logistické regrese je stanovení jednotlivých cílů. Jak uvádí Hair (2009), logistická regrese si klade velmi podobné cíle jako diskriminační analýza. Mezi hlavní cíle lze zařadit hledání takových nezávisle proměnných, které mají vliv na závislou proměnnou a také stanovení klasifikačního systému, podle kterého budou objekty zařazovány do jednotlivých skupin. Výběrový soubor dat lze rozdělit na analyzovaný a klasifikovaný soubor. Analyzovaný soubor slouží k odvození modelu, klasifikovaný poté k ověření predikční schopnosti.

3.5.2 Odhad logistického modelu

V rámci druhého kroku metody logistické regrese je potřeba především určit potřebný vzorek dat, definovat logistický model a odhadnout regresní koeficienty.

Velikost výběrového vzorku

Aby nedocházelo ke zkreslování výsledného modelu, je doporučována velikost jak daného výběru, tak i počtu pozorování na jednu nezávisle proměnnou. Jak uvádí Hair (2009), doporučuje Hosmer a Lemeshow, aby počet dat ve výběru nebyl menší než 400. Zároveň je dle Hair (2009) doporučováno, aby pro každou skupinu byl dodržen poměr 10 pozorování na jednu nezávisle proměnnou. Z dříve uvedených doporučení vyplývá, že metoda logistické regrese je mnohem náročnější na velikost výběrového souboru oproti např. diskriminační nebo regresní analýze.

Stanovení závislé proměnné

Jak již bylo definováno v hlavním cíli logistické regrese, závislá proměnná je vysvětlována nezávislými proměnnými. Dle Meloun (2006), lze dle typu vysvětlující proměnné rozlišovat mezi následujícími typy logistické regrese:

- **binární**, týkající se závislé proměnné nebo znaku, které mohou nabývat pouze dvou hodnot, např. muž x žena,
- **ordinální**, týkající se ordinální závisle proměnné nebo znaku, které mohou nabývat tří a více stavů, např. ano, ne, možná,
- **nominální**, týkající se nominální závisle proměnné nebo znaku o více než třech různých úrovních stavů, které jsou definovány s odlišnostmi.

V rámci této diplomové práce bude mít závislá proměnná binární podobu. Proměnnou Y nazýváme binární v případě, že s pravděpodobností π bude nabývat hodnoty 1 a s pravděpodobností $(1-\pi)$ hodnoty 0. Pravděpodobnost, že dojde k určité události je dána intervalem $\langle 0;1 \rangle$. Jelikož se pracuje s poměrně omezeným intervalem, je potřeba existenci či neexistenci určitého jevu převést na poměr pravděpodobností. Poměr pravděpodobností se nazývá šance (odds) a lze zapsat dle následujícího vztahu:

$$odds = \frac{\pi}{1-\pi}, \quad (3.14)$$

kdy může být dosaženo jakékoliv nezáporné hodnoty z intervalu $\langle 0, \infty \rangle$. Aby mohlo být dosaženo hodnoty v intervalu $\langle -\infty; \infty \rangle$, je potřeba provést transformaci pomocí logaritmické funkce $\ln \frac{\pi}{1-\pi}$. Následně lze vyjádřit logistický model, který má následující podobu:

$$\pi(x) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}}. \quad (3.15)$$

Dle Hosmer, Lemeshow (2000), lze logistický model pomocí transformace $\pi(x)$ převést na tzv. logit, který má následnou podobu:

$$g(x) = \ln \left[\frac{\pi(x)}{1-\pi(x)} \right] = \beta_0 + \beta_1 x. \quad (3.16)$$

Odhad regresních koeficientů

Jelikož se v případě logistické regrese pracuje s binární proměnnou, nemůže být k odhadu jednotlivých proměnných využita metoda nejmenších čtverců, ale lze využít metodu maximální věrohodnosti. Věrohodnostní funkce má v případě binomického rozdělení následující tvar:

$$l(\beta) = \prod_{i=1}^n \pi(x_i)^{y_i} [1-\pi(x_i)]^{1-y_i}. \quad (3.17)$$

Jak název metody napovídá, je potřeba tuto věrohodnostní funkci maximalizovat. Dle Meloun (2006), lze tedy maximalizaci logaritmu věrohodnostní funkce, za předpokladu binomického rozdělení y , zapsat v následujícím tvaru:

$$\ln[l(\beta)] = \sum_{i=1}^n \{y_i \ln[\pi(x_i)] + (1-y_i) \ln[1-\pi(x_i)]\}. \quad (3.18)$$

K odhadu logistických koeficientů je možno v analytických počítačových programech využít přímou (enter) nebo krokovou metodu. V případě přímé metody jsou do modelu vloženy všechny prediktory do jednoho bloku a pro tento blok jsou vypočteny jednotlivé odhady parametrů.

Druhou možností je využití krokové metody. Podstatou krokové metody je postupné přidávání a naopak vyřazování jednotlivých proměnných na základě dosažené významnosti. Dle Field (2009), lze u krokové metody využít postup vpřed (Forward selection), nebo vzad (Backward selection). Při využití Forward selection se začíná s prázdným modelem, který neobsahuje žádné proměnné, které jsou však v následujících krocích postupně přidávány. Do modelu jsou přidávány proměnné, které v daném kroku dosahují nejvyššího skóre. Druhou možností je využití Backward selection metody. V tomto případě jsou do modelu zařazeny všechny proměnné, které jsou následně v jednotlivých krocích vyřazovány v případě, že nesplňují požadovanou hladinu významnosti.

Testování významnosti koeficientů

Po odhadu jednotlivých regresních koeficientů je potřeba testovat jejich významnost, čímž se zjišťuje, zda-li se v logistickém regresním modelu liší od nuly. V případě, že by se koeficient rovnal nule, nastala by situace, že pravděpodobnostní poměr se nemění a tudíž proměnná nemá vliv na pravděpodobnost. K testování významnosti koeficientů lze využít Waldovo testovací kritérium. Toto kritérium lze zapsat dle následujícího vztahu:

$$W_{a,i} = \frac{b_i^2}{s^2(b_i)}, \quad (3.19)$$

kde b_i^2 je čtverec poměru odhadu regresního koeficientu a $s^2(b_i)$ směrodatná odchylka regresního koeficientu. Waldova statistika má $W_{a,i}$ má χ^2 -rozdělení s jedním stupněm volnosti.

3.5.3 Ověření správnosti modelu

K ověřování správnosti daného modelu slouží míra těsnosti proložením logistickým modelem. Jak uvádí Meloun (2006), je mírou těsnosti proložení navrženého modelu daty hodnota pravděpodobnosti $L_{(1)}$, že se daná událost uskuteční. Místo pravděpodobnosti $L_{(1)}$, se využívá odchylka, kterou lze znázornit dle následujícího vzorce:

$$D = -2 \ln L_{(1)}, \quad (3.20)$$

kteou lze označit také jako $-2LL$. Čím více se hodnota odchylky blíží k nule, tím lepšího

proložení je dosaženo. Pomocí odchylky lze také hodnotit dva regresní modely. V tomto případě se srovnává model bez proměnných s modelem obsahující proměnné. Tento vztah lze zapsat pomocí následujícího vzorce:

$$G = -2 \ln \frac{\text{pravděpodobnost modelu bez proměnných}}{\text{pravděpodobnost modelu s proměnnými}}, \quad (3.21)$$

který odpovídá věrohodnostnímu poměru. Model, který obsahuje proměnné, by měl dosahovat mnohem nižší hodnoty $-2LL$, než model bez těchto proměnných.

Dle Řeháková (2000), bylo pro ověření modelu také navrženo mnoho analogických postupů ke koeficientu determinace R^2 , který se využívá v lineární regresi. Mezi takovéto koeficienty determinace můžeme zařadit R^2 Coxové a Snella a R^2 Nagelkerka. V obou případech se R^2 může pohybovat v intervalu od 0 do 1. R^2 Nagelkera byl navržen jako modifikace R^2 Coxové a Snella, neboť tento koeficient nikdy nemohl dosáhnout hodnoty 1. Pro R^2 Nagelkerka tedy platí, že čím bližší je dosažená hodnota číslu jedna, tím lépe dokáže daný model vysvětlovat změnu závislé proměnné pomocí nezávislých proměnných.

3.5.4 Interpretace výsledků

Pro správné využití odvozeného regresního modelu je důležitá interpretace regresních koeficientů. Dle Řeháková (2000) lze koeficient β_k interpretovat jako změnu závisle proměnné spojenou se změnou hodnoty nezávisle proměnné, za předpokladu neměnných hodnot ostatních proměnných. Pokud je hodnota koeficientu β_k vyšší než 0, daná proměnná pozitivně přispívá ke zvýšení šance k určitému jevu, naopak hodnota koeficientu β_k menší než 0 snižuje šanci k existenci určitého jevu. V případě, že je hodnota koeficientu β_k rovna 0, šance se nezmění.

Odlišná interpretace nastává v případě exponenciálních regresních koeficientů. V tomto případě se jedná o logaritmy původních regresních koeficientů β_k , které nemohou nabývat záporných hodnot. Tyto koeficienty jsou značeny jako $\exp(\beta_k)$. Pro získání jednotlivých exponenciálních regresních koeficientů se využívá postup, kdy se porovnávají pravděpodobnosti, že daná událost nastane, či nikoliv. Tento vztah lze zapsat dle následujícího vzorce:

$$\exp(\beta_k) = \frac{\pi(P_1)}{\pi(P_0)} = e^{B_0 + B_1 X_1 + B_2 X_2 + \dots + B_n X_n}, \quad (3.22)$$

kde $\pi(P_1)$ vyjadřuje pravděpodobnost, že daná situace nastane, $\pi(P_0)$ je pravděpodobnost, že

situace nenastane. Pokud je hodnota $\exp(\beta_k) < 1$, nezávisle proměnná negativně působí na vysvětlovanou proměnnou, v případě $\exp(\beta_k) > 1$ pozitivně.

3.5.5 Ověření predikční síly

Následným krokem po odvození logistického modelu a interpretaci výsledků je ověření predikční síly. Predikční sílu modelu lze hodnotit pomocí klasifikační matice a ROC křivky.

Klasifikační matice

Účelem klasifikační matice je zobrazení zařazení dosažených hodnot do jednotlivých předem definovaných skupin. Následující tabulka (Tab. 3.1) zobrazuje základní strukturu klasifikační matice.

Tab. 3.1 Klasifikační matice

Skutečná skupina	Predikovaná skupina	
	Skupina A	Skupina B
Skupina A	I. správná predikce sk. A	II. nesprávná predikce sk. A
Skupina B	III. nesprávná predikce sk. B	IV. správná predikce sk. B

Zdroj: Meloun (2006, str. 302)

Matice obsahuje celkem čtyři kvadráty. První dva kvadráty sledují vývoj skupiny A. První kvadrát (I.) zobrazuje počet správně zařazených prvků do skupiny A. Druhý kvadrát (II.) zobrazuje počet testovaných prvků, které byly zařazeny nesprávně do skupiny A. Zbývající dva kvadráty sledují vývoj skupiny B. Třetí kvadrát (III.) zobrazuje počet nesprávně zařazených prvků mezi skupinu B. Čtvrtý kvadrát (IV.) zobrazuje počet správně zařazených prvků do skupiny B.


Pomocí klasifikační matice lze také hodnotit celkovou predikční schopnost vytvořených modelů. Poměr správně zařazených prvků lze získat, když je součet prvního (I.) a čtvrtého (IV.) kvadrátu vydělen celkovým počtem analyzovaných prvků dat. Obdobně lze hodnotit počet nesprávně zařazených prvků, druhý (II.) a třetí (III.) kvadrát je vydělen celkovým počtem dat v klasifikovaném souboru.

ROC křivka

Dalším nástrojem pro ověření klasifikační síly vytvořeného modelu je křivka ROC (Receiver Operating Characteristic). Pomocí křivky lze zobrazit vztah mezi specificitou

a senzitivitou testovaného vzorku dat. **Senzitivita** vyjadřuje pravděpodobnost, že kladnému objektu bude přidělen kladný výsledek ve vztahu ke zkoumanému jevu. Naproti tomu **specifita** vyjadřuje pravděpodobnost, že negativnímu objektu bude přidělen negativní výsledek, ve vztahu ke zkoumanému jevu. ROC křivku je možno vyjádřit pomocí grafu (Obr. 3.2). Jedná se o dvojrozměrný graf, kdy na osu x jsou nanášeny pravděpodobnosti nesprávného zařazení objektů, které jsou ve skutečnosti pozitivní a na osu y jsou nanášeny pravděpodobnosti správného zařazení pozitivních objektů.

Obr. 3.3 ROC křivka



Zdroj: medcalc.org¹

Při testování predikční síly pomocí ROC křivky mohou nastat dvě extrémní situace. V případě, že má ROC křivka tvar diagonály, není model vhodný k následné predikci, neboť postrádá diskriminační schopnost. Druhou extrémní situací je, pokud ROC křivka splývá s levým horním rohem. V tomto případě existuje maximální shoda mezi skutečnou a predikovanou skupinou a model je tudíž vhodný k následné predikci.

V souvislosti s ROC křivkou se pracuje také s hodnotou ukazatele AUC. Hodnota AUC vyjadřuje plochu pod ROC křivkou. Tento ukazatel se využívá především pro srovnání dvou a více ROC křivek, kdy se tyto křivky převádějí na jednu skalární veličinu, kterou je možno následně hodnotit. Hodnota ukazatele se pohybuje v intervalu od 0,5 do 1. Následující tabulka (Tab. 3.2) zobrazuje hodnocení přesnosti testu.

¹ http://www.medcalc.org/manual/_help/images/roc_intro3.png

Tab. 3.2 Hodnocení AUC

AUC	Hodnocení
0,9 – 1,0	výborný
0,8 – 0,9	dobrý
0,7 – 0,8	obstojný
0,6 – 0,7	špatný
0,5 – 0,6	neúspěšný

Zdroj: <http://gim.unmc.edu/>²

² <http://gim.unmc.edu/dxtests/roc3.htm>

4 Aplikace vybraných metod a odhad predikčního modelu

Obsahem čtvrté kapitoly je aplikace teoretických přístupů popsaných v předešlých kapitolách na konkrétní finanční data jednotlivých firem. První část této kapitoly je zaměřena na tvorbu predikčního modelu pomocí diskriminační analýzy, druhá část obsahuje odhad predikčního modelu pomocí logistické regrese a v závěru kapitoly jsou obě metody srovnány. K vytvoření jednotlivých modelů budou využity analytické počítačové programy PASW Statistics 18 (SPSS) a MS Excel.

Odhad jednotlivých modelů je tvořen na vzorku českých firem, celkem existovalo k 1.1.2012 v České republice 357 701³ obchodních společností. V období od 1.1.2012 do 31.12.2012 byl zaznamenán bankrot u 3 692⁴ obchodních společností, což představovalo podíl 1,03 % na celkovém počtu firem. Nejvíce vyhlášených bankrotů bylo zaznamenáno v oblasti stavebnictví, pohostinství a obchodu.

4.1 Popis vstupních dat

Vstupní data využívaná v diplomové práci lze rozdělit na dvě základní skupiny. První skupinu tvoří finanční výkazy firem za účetní rok 2011, které se v následujícím roce 2012 neocitly ve finanční tísní. Výkazy jednotlivých firem, které se neocitly ve finanční tísní, byly získány prostřednictvím elektronické verze Obchodního rejstříku⁵. Skupinu finančně zdravých firem tvoří 249 společností. Druhou skupinu tvoří finanční výkazy firem za účetní rok 2011, u kterých se v roce 2012 vyskytly znaky, které lze považovat za finanční tíseň. Mezi znaky, díky kterým lze považovat firmy nacházející se ve finanční tísní patří např. vyhlášení úpadku, likvidace, konkurzu nebo zahájení insolvenčního řízení na návrh věřitele či dlužníka. Informace o výskytu znaků finanční tísně byly zjištěny prostřednictvím Insolvenčního rejstříků⁶, finanční výkazy jednotlivých firem byly získány prostřednictvím databázového informačního systému MagnusWeb⁷. Skupinu firem se znaky finanční tísně tvoří 180 firem.

Celkem byly shromážděny a zpracovány finanční výkazy od 429 firem. Pro potřeby diplomové práce byl soubor rozdělen na 2 skupiny. První skupinu tvoří finanční výkazy 370 firem, což představuje analyzovaný soubor, prostřednictvím kterého bude vytvořen model

³ <http://www.cekia.cz/cz/archiv-tiskovych-zprav/315-tz120116>

⁴ <http://www.investujeme.cz/v-roce-2012-bylo-vyhlaseno-16-956-osobnich-bankrotu-firem-zbankrotovalo-3-692/>

⁵ <http://portal.justice.cz/Justice2/Uvod/Uvod.aspx>

⁶ <https://isir.justice.cz/isir/common/index.do>

⁷ <http://www.cekia.cz/magnusweb>

úpadku. Druhou skupinu tvoří 59 firem, představující klasifikovaný soubor, pomocí kterého bude probíhat ověřování vytvořeného predikčního modelu.

Hlavním zdrojem dat k tvorbě predikčního modelu jsou data finanční analýzy. Na finanční výkazy 429 firem bylo aplikováno 23 poměrových ukazatelů z oblasti rentability, likvidity, aktivity, zadluženosti a stability. Z oblasti rentability byla konkrétně sledována rentabilita aktiv, vlastního kapitálu, dlouhodobých zdrojů, tržeb a finanční páka. Oblast likvidity sledovala celkovou, okamžitou a běžnou likviditu. Pomocí ukazatelů aktivity byl sledován vývoj obratu aktiv a zásob, dále doba obratu aktiv, zásob, pohledávek a doba úhrady krátkodobých závazků. Oblast zadluženosti a stability se věnovala podílu vlastního kapitálu na celkových aktivech, stupně krytí stálých aktiv, podílu stálých aktiv na celkových aktivech, podílů oběžných aktiv na celkových aktivech, úrokovému zatížení, celkové, dlouhodobé a běžné zadluženosti. Kromě typických ukazatelů poměrové analýzy byl také využit ukazatel velikosti firem, který porovnává velikost jednotlivých firem pomocí objemu celkových aktiv. Jednotlivé ukazatele finanční i nefinanční analýzy byly vypočteny pomocí vzorců (2.1) až (2.23).

Po provedení finanční analýzy bylo zjištěno, že některé ukazatele není možno využít k následnému modelování finanční tísně z důvodu nelogických hodnot. Prvním ukazatelem nevhodným pro modelování je rentabilita vlastního kapitálu. Problémem ukazatele ROE je záporná hodnota vlastního kapitálu, která je častým jevem u firem v tísní. Kombinace záporné hodnoty vlastního kapitálu se zápornou hodnotou zisku tvoří kladnou hodnotu ROE. Dále bylo rozhodnuto o vyřazení ukazatele doby obratu zásob a obratu zásob z důvodu rozsáhlého počtu firem nevykazujících ve finančních výkazech položku zásob. Z následné analýzy byl také vyřazen ukazatel stupně krytí stálých aktiv, u kterých z důvodu absence položky dlouhodobých aktiv u mnoha firem docházelo k výpočtu nereálných hodnot. Posledním vyřazeným ukazatelem je podíl stálých aktiv na celkových aktivech, jehož funkci plně zastoupí ukazatel podílu oběžných aktiv na celkových aktivech.

Po vyřazení ukazatelů, které by přispívaly ke zkreslování výsledných hodnot, nebo nemožnosti výpočtu bylo provedeno odstranění 5 firem vykazujících záporné zadlužení a 41 firem, u kterých nemohla být provedena finanční analýza z důvodu chybějících klíčových položek ve finančních výkazech.

4.2 Diskriminační analýza

Prvním krokem diskriminační analýzy je rozdělení analyzovaného souboru, který po očištění čítá 324 firem. První skupinu tvoří 209, u kterých nebyla zaznamenána finanční tíseň. Této skupině byla přiřazena hodnota bankrotu 0. Druhou skupinu tvoří firmy, u kterých byla zaznamenána finanční tíseň v roce 2012. Druhá skupina je tvořena 115 společnostmi a hodnota bankrotu činí 1.

K ověření správnosti diskriminační funkce bude využit klasifikovaný vzorek. Klasifikovaný vzorek obsahuje 29 firem, které se nacházejí ve skupině 0 a 30 firem, které obsahuje skupina 1.

4.2.1 Multikolinearita

Důležitým krokem analýzy je sledování multikolinearity. Vysvětlující proměnné se považují za závislé, pokud je mezi nimi párová korelace vyšší než 0,8. Výpočet multikolinearity mezi jednotlivými vysvětlujícími proměnnými zobrazuje Příloha 1.

Nalezena byla závislost mezi běžnou a celkovou likviditou, dobou obratu aktiv a rentabilitou tržeb. Dále byla nalezena multikolinearita mezi rentabilitou aktiv spolu s podílem vlastního kapitálu na aktivech, celkovou zadlužeností a běžnou zadlužeností. Vysoká hodnota párové korelace byla dále zaznamenána mezi celkovou zadlužeností spolu s podílem vlastního kapitálu na celkových aktivech a celkovou zadlužeností a také mezi běžnou zadlužeností a podílem vlastního kapitálu na celkových aktivech.

Díky dříve uvedeným párovým korelacím vyšším než 0,8 je potřeba některé vysvětlující proměnné vyřadit. Rozhodujícím kritériem k vyřazení je velikost párové korelace jednotlivých ukazatelů k vysvětlované proměnné (bankrotu). Z tohoto důvodu byly vyřazeny ukazatele podílu vlastního kapitálu na celkových aktivech, celková zadluženost, běžná zadluženost, běžná likvidita a doba obratu aktiv.

4.2.2 Popisná statistika

Následující podkapitola vyjadřuje základní statistické charakteristiky jednotlivých poměrových ukazatelů finanční analýzy. Níže uvedená tabulka (Tab. 4.1) zobrazuje střední hodnoty jednotlivých poměrových ukazatelů, vypočteny dle (3.1), procentní podíl na sumě obou skupin a rozdíl středních hodnot.

Tab. 4.1 Střední hodnoty a procentní podíly skupiny 0 a 1

	ROA	ROCE	FIN_PAK	ROS	CEL_LIK	OK_LIK	OB_AKT
Sk. 0	0,04	0,12	2,24	0,03	7,28	2,29	1,45
Sk. 1	-0,49	0,31	0,74	-1,08	2,24	1,56	9,37
Suma	-0,45	0,43	2,98	-1,06	9,52	3,84	10,83
Podíl sk. 0	-9,58	28,84	75,23	-2,46	76,45	59,52	13,41
Podíl sk. 1	109,58	71,16	24,77	102,46	23,55	40,48	86,59
Rozdíl	-119,16	-42,33	50,46	-104,93	52,90	19,05	-73,19
	DS_POH	DÚ_KZ	OA_CA	DL_ZAD	ÚR_ZAT	VEL	-
Sk. 0	362,66	178,23	0,54	0,22	0,01	10,89	-
Sk. 1	680,58	1 769,80	0,66	0,65	-0,19	8,78	-
Suma	1 043,23	1 948,00	1,20	0,86	-0,18	19,67	-
Podíl sk. 0	34,76	9,15	44,83	25,22	-3,68	55,37	-
Podíl sk. 1	65,24	90,85	55,17	74,78	103,68	44,63	-
Rozdíl	-30,47	-81,70	-10,34	-49,56	-107,36	10,74	-

Zdroj: vlastní zpracování

Největší rozdíly mezi středními hodnotami skupiny 0 a 1 byly zaznamenány mezi ukazateli rentability aktiv, rentability tržeb, obratu aktiv, doby úhrady krátkodobých závazků a úrokového zatížení. Dá se tedy předpokládat, že výše zmíněné ukazatele budou významně přispívat k rozdílnosti skupiny 0 a 1.

4.2.3 Kroková metoda

V následující části je popsána aplikace krokové metody na finanční ukazatele firem skupiny 0 a 1. Stepwise metoda je metoda, která slouží k vytvoření modelu přidáváním nebo odebráním proměnných, založená na t-statistice jejich odhadnutých koeficientů. K využití metody byly využity finanční ukazatele, které zůstaly po vyřazení nevhodných ukazatelů a provedení testování multikolinearity. Celkově bylo ke krokové analýze využito 13 ukazatelů. Diskriminační analýza byla provedena prostřednictvím programu PASW Statistics.

Rozhodujícím kritériem krokové metody je Wilksova lambda. V každém kroku je vybrán finanční ukazatel, který nejvíce přispívá k diskriminaci mezi skupinou 0 a 1. Prvotně je vždy do modelu zařazen ten ukazatel, který způsobuje nejmenší hodnotu Wilkovy lambdy v daném kroku analýzy. Tabulky v přílohách (Příloha 2, Příloha 3, Příloha 4) zobrazují vývoj jednotlivých charakteristik Stepwise metody v kroku 0 až 5. Sledována je tolerance, minimální tolerance, F-statistika a Wilksova lambda. Hodnota sloupce tolerance je v nultém kroku nastavena na hodnotu 1, což znamená, že v modelu nejsou vybrány ještě žádné diskriminátory. Čím nižší je dosažená hodnota v sloupci tolerance, tím větší je daný ukazatel

přímou kombinací již vybraných diskriminátorů, a tím menší je jeho pravděpodobnost, že v dalším kroku bude vybrán jako vhodný diskriminátor. Pomocí sloupce F to entry lze poměřovat relativní diskriminační sílu jednotlivých ukazatelů. Čím vyšší je relativní diskriminační síla jednotlivých ukazatelů, tím vyšší je pravděpodobnost zařazení ukazatele do diskriminační funkce.

Jak je uvedeno v příloze (Příloha 2), v nultém kroku Stepwise metody byl vybrán ukazatel velikosti aktiv. Ukazatel velikosti aktiv byl vybrán na základě nejnížší hodnoty Wilksovy lambdy, která dosahuje hodnoty 0,812. Zároveň byla u ukazatele velikosti podniku dosažena nejvyšší hodnota F-statistiky a to konkrétně 74,376, z čeho vyplývá, že ukazatel dosahuje vysoké významnosti vůči závislé proměnné. Hodnota míry tolerance je rovna hodnotě 1, neboť v modelu nejsou vybrány ještě žádné jiné diskriminátory.

Po provedení nultého kroku a získání prvního diskriminátoru následuje krok první. V prvním kroku lze sledovat, že po odebrání ukazatele velikosti aktiv došlo k přepočtení všech charakteristik. Došlo ke snížení míry tolerance, jelikož mezi prvním diskriminátorem a proměnnými, které zůstávají v analýze, existuje určitá míra lineární závislosti. Dle kritéria nejnížší hodnoty Wilksovy lambdy byl jako další diskriminátor vybrán ukazatel doby úhrady krátkodobých závazků. Hodnota Wilksovy lambdy tohoto ukazatele činí 0,779 a hodnota F-statistiky 13,892. Hodnota míry tolerance dosahuje výše 0,999 a lze tedy konstatovat, že mezi ukazatelem velikosti aktiv a dobou úhrady krátkodobých závazků aktiv neexistuje téměř žádná lineární závislost.

Jak je uvedeno v příloze (Příloha 3), po získání dalšího diskriminátoru a odebrání ukazatele doby úhrady krátkodobých závazků proběhlo přepočtení všech zbylých proměnných v krokové metodě. Jako další diskriminátor byl podle kritéria nejnížší Wilksovy lambdy vybrán ukazatel rentability aktiv. Hodnota lambdy u ukazatele ROA činí 0,749, hodnota F-statistiky 12,498. Z dosažených výsledků je také patrné, že došlo ke snížení hodnoty míry tolerance. V tomto případě bylo dosaženo míry tolerance ve výši 0,881, což ukazuje na určitou lineární závislost mezi ukazatelem rentability aktiv a dříve vybranými diskriminátory.

Následuje třetí krok Stepwise metody, kdy byl pomocí kritéria nejnížší hodnoty Wilksovy lambdy vybrán ukazatel podílu oběžných aktiv na celkových aktivech. Diskriminant vstupuje do analýzy s hodnotou Wilksovy lambdy ve výši 0,726 a hodnotou F-statistiky ve výši 10,126. Hodnota míry tolerance dosahuje výše 0,924.

Po přepočtení jednotlivých hodnot a získání čtvrtého diskriminátoru následuje krok čtvrtý. V příloze (Příloha 4) je patrné, že nejnižší hodnotu Wilksovy lambdy má ukazatel finanční páky. Hodnota F-statistiky tohoto ukazatele činí 5,705. Hodnota míry tolerance dosahuje výše 0,933, z čehož vyplývá pouze slabá lineární závislost mezi vybraným diskriminátorem a již zařazenými diskriminátory v modelu. Poslední tabulka zobrazuje krok pátý. V tomto kroku lze v tabulce sledovat ukazatele, které již do diskriminační funkce nevstupují. Rozhodujícím kritériem pro nevstupování dalších ukazatelů do diskriminační funkce je hodnota F-statistiky. Minimální hranice F-statistiky na hladině pravděpodobnosti 0,05 byla vypočtena v MS Excel pro daný počet jednotek ve výběru:

$$FINV = (0,05; 324) = 3,87.$$

Dalšími ukazateli, jenž by se mohli stát diskriminátory dle kritéria Wilksovy lambdy mezi bankrotujícími a nebankrotujícími firmami, je ukazatel celkové likvidity, nebo úrokového zatížení. Z důvodu nižší hodnoty F-statistiky než F kritická nebudou tyto ukazatele zařazeny do diskriminační funkce.

Následující tabulka (Tab. 4.2) zobrazuje shrnutí výběru jednotlivých proměnných v 5 krocích.

Tab. 4.2 Wilksova lambda

Step	Variables	Lambda	df1	df2	df3	Exact F			
						Statistic	df1	df2	Sig.
1	1	0,812	1	1	322	74,376	1	322	0
2	2	0,779	2	1	322	45,623	2	321	0
3	3	0,749	3	1	322	35,671	3	320	0
4	4	0,726	4	1	322	30,048	4	319	0
5	5	0,714	5	1	322	25,534	5	318	0

Zdroj: vlastní zpracování

Ve sloupci Lambda můžeme pozorovat snížení hodnoty Wilksovy lambdy z 0,812 na 0,714. K snížení Wilksovy lambdy došlo z důvodu přidání dalších diskriminantů k původnímu ukazateli velikosti aktiv.

4.2.4 Odvození diskriminační funkce

Po provedení jednotlivých kroků Stepwise metody je možno stanovit diskriminační funkci pomocí jednotlivých koeficientů. Ke stanovení diskriminační funkce jsou využity

kanonické nestandardizované koeficienty, které jsou zobrazeny v následující tabulce (Tab. 4.3).

Tab. 4.3 Kanonické koeficienty diskriminační funkce

	Function
	1
ROA	0,6291
FIN_PAK	0,0659
DÚ_KZ	-0,0001
OA_CA	-1,1133
VEL	0,2534
(Constant)	-1,8447

Zdroj: vlastní zpracování

Dle dosažených koeficientů lze sestavit diskriminační rovnici, která má následující tvar:

$$Z = -1,8447 + 0,6291 \cdot ROA + 0,0659 \cdot FIN_PAK - 0,0001 \cdot DÚ_KZ - 1,1133 \cdot OA_CA + 0,2534 \cdot VEL.$$

Pomocí diskriminační rovnice lze vypočítat výsledné skóre pro každou jednotlivou firmu z klasifikačního vzorku. Kritériem pro zařazení jednotlivých firem do skupiny 0, nebo skupiny 1 je hodnota prahového bodu. K výpočtu prahových bodů je potřeba využít hodnot nestandardizovaných kanonických diskriminačních funkcí pro jednotlivé skupiny. Tyto hodnoty zobrazuje následující tabulka (Tab. 4.4).


Tab. 4.4 Nestandardizované kanonické diskriminační funkce sk. 0 a 1

Bankrot	Function
	1
0	0,469
1	-0,852

Zdroj: vlastní zpracování

Následující graf (Graf 4.1) zobrazuje kanonické diskriminační funkce skupiny 0 a skupiny 1. U skupiny 0 je možno pozorovat, že počet sledovaných dat byl 209, střední hodnota 0,47 a směrodatná odchylka 0,685. U skupiny 1 je celkem 115 pozorování, střední hodnota je -0,85 a směrodatná odchylka 1,403.

Graf 4.1 Grafy kanonických diskriminančních funkcí skupiny 0 a 1



4.2.5 Výpočet prahového bodu

Jelikož je pro výpočet modelu bankrotu využito dvou nestejně velkých skupin, bude k výpočtu prahového bodu využita metoda váženého průměru. Dle vzorce (3.10) lze vypočítat prahový bod:

$$PB = \frac{209 \cdot 0,469 + 115 \cdot (-0,852)}{209 + 115} = 0,0001265.$$

Dle předchozího výpočtu bylo zjištěno, že výše prahového bodu dosahuje hodnoty 0,0001265. Následujícím krokem je výpočet Z skóre pro každou firmu z klasifikačního vzorku. Pokud je dosažena hodnota Z skóre vyšší než stanovený prahový bod, tj. 0,0001265, je firma zařazena do predikční skupiny 0, pokud je naopak vypočtená hodnota menší než hodnota prahového bodu, je firma zařazena do predikční skupiny 1. Po zařazení jednotlivých firem z klasifikačního vzorku do jednotlivé predikční skupiny, je potřeba vyčíslit úspěšnost jednotlivého zařazení.

4.2.6 Klasifikační matice analyzovaného vzorku dat

Následující tabulka (Tab. 4.5) zobrazuje klasifikační matici vstupního analyzovaného vzorku dat. Účelem klasifikační matice je ověření, jaká je klasifikační schopnost diskriminační funkce. Jde tedy o zobrazení zpětného zařazení jednotlivých firem dle nově vytvořené diskriminační funkce a vypočteného prahového bodu. V tabulce je možno sledovat počet správně zařazených firem do skupiny, počet nesprávně zařazených firem a celkový počet firem v každé skupině.

Tab. 4.5 Klasifikační matice vstupního vzorku

skutečná skupina	Predikovaná skupina		Celkem
	0	1	
0	178	31	209
1	34	81	115
% podíl	85,17	14,83	100
% podíl	29,56	70,44	100

Zdroj: vlastní zpracování

První řádek zobrazuje skupinu 0, tj. skupinu, u níž se nevyskytly znaky finanční tísně. Celkově bylo do skupiny 0 zařazeno 209 firem. Z tohoto počtu byla správně predikována bankrotní skupina 0 pro 178 firem. Celkově bylo tedy správně zařazeno 85,17 % firem. Naopak nesprávně bylo do skupiny 0 zařazeno 31 společností, což představuje podíl ve výši 14,83 %.

Druhou skupinu představují firmy, u kterých se objevily znaky finanční tísně. Celkově obsahuje druhá skupina 115 firem. Z tohoto celkového počtu firem bylo zpětně dle diskriminační funkce správně do skupiny 1 zařazeno 81 firem. Tento počet představuje na celkovém počtu 70,44 %. Naopak nesprávně bylo zařazeno 34 firem, což představuje podíl 29,56 %.

Celkem byla správně predikována skupina u 259 z 324 firem, což představuje podíl 79,90 %. Z dosažených výsledků je patrné, že dle stanovené diskriminační funkce lze přesněji predikovat bankrotní skupinu u firem, které nevykazují znaky finanční tísně.

Dalším důležitým krokem je ověření, zda-li je predikční schopnost u analyzovaného vzorku dat dostatečná pro predikci finanční tísně u klasifikovaného vzorku. Dostatečnost vypovídací schopnosti bude ověřena pomocí Pressovy q-statistiky a tzv. hit testů.

Pressova q-statistika diskriminační síly

Pressova q-statistika diskriminační síly porovnává hodnotu vypočtené q statistiky s kritickou hodnotu chi-kvadrátu. Následující rovnice zobrazuje výpočet dle vzorce (3.11):

$$q = \frac{(324 - 259 \cdot 2)^2}{324(2 - 1)} = 116,16.$$

Dle výpočtu bylo zjištěno, že hodnota vypočtené q-statistiky dosahuje hodnoty 116,16. Tuto hodnotu je potřeba porovnat s kritickou hodnotou chi-kvadrátu na hladině významnosti 0,05. Kritická hodnota chi-kvadrátu na hladině pravděpodobnosti 0,05 byla zjištěna pomocí programu MS Excel následujícím způsobem:

$$CHIINV(0,05;1) = 3,84.$$

Při srovnání vypočtené q-statistiky s q-statistikou vypočtenou bylo zjištěno, že q vypočtená je větší, tudíž lze konstatovat, že predikční schopnost diskriminační funkce ve výši 79,9 % je dostatečná.

Kritérium maximální věrohodnosti

Principem kritéria maximální věrohodnosti je hodnocení přesnosti klasifikace pomocí vyčíslení procenta zastoupení nejpočetnější skupiny na celkovém počtu členů ve vzorku. V tomto případě byla nejpočetnější skupina číslo 0, v které se nacházelo 209 sledovaných firem. Průběh výpočtu dle vzorce (3.12) zobrazuje následující vztah:

$$h = (209 / 324) \cdot 100 = 64,05 \, \%.$$

Jelikož je dosažená klasifikační schopnost modelu (79,9 %) vyšší než minimální požadovaná klasifikační schopnost, je model vhodný pro následné ověření na klasifikovaném vzorku dat.

Kritérium poměrové pravděpodobnosti

Posledním kritériem, pomocí kterého je možno ověřit klasifikační schopnost stanovené diskriminační funkce je poměrová pravděpodobnost. Kritérium poměrové pravděpodobnosti lze vypočítat dle vzorce (3.13) a je zobrazeno následujícím vztahem:

$$\pi = 0,64^2 + (1 - 0,64)^2 = 0,54.$$

Také dle kritéria poměrové pravděpodobnosti bylo zjištěno, že klasifikační síla je dostatečná, neboť je vyšší, než minimálně požadovaná.

4.2.7 Klasifikační matice klasifikovaného vzorku dat

V následující části je ověřena spolehlivost diskriminační funkce na vzorku firem, který byl vyčleněn k ověření klasifikace. Klasifikační vzorek představuje 59 firem, které tvoří dvě skupiny. První skupina obsahuje firmy, u kterých nebyly nalezeny znaky tísně. Tyto firmy jsou označeny hodnotou 0. Druhou skupinu představují firmy, které jeví znaky finanční tísně a jsou označeny hodnotou 1.

Tab. 4.6 Klasifikační matice klasifikovaného vzorku dat

skutečná skupina	Predikovaná skupina		Celkem
	0	1	
0	25	4	29
1	7	23	30
% podíl	86,21	13,79	100
% podíl	23,33	76,67	100

Zdroj: vlastní zpracování

Předchozí tabulka (Tab. 4.6) zobrazuje predikci přiřazení jednotlivých firem klasifikovaného vzorku do skupiny 0, nebo 1. Na prvním řádku je možno pozorovat, že skupina 0 celkem obsahovala 29 firem. Z tohoto počtu bylo správně do skupiny 0 zařazeno 25 firem, tato hodnota představuje podíl ve výši 86,21 %. Naopak špatně byly do skupiny 0 zařazeny 4 firmy. Podíl špatně zařazených firem představuje 13,79 %.

Při klasifikaci skupiny 1 bylo celkově ke klasifikaci využito 30 společností. Při této klasifikaci bylo správně zařazeno do bankrotní skupiny 1 celkem 21 firem. Tato hodnota představuje podíl 76,67 % na souhrnném počtu firem v dané testované skupině. Naopak špatně byla predikována konečná skupina u 7 firem. V procentním vyjádření se jednalo o špatné zařazení ve výši 23,3 %.

Při hodnocení úspěšnosti zařazení jednotlivých firem do vhodné skupiny, bylo správně zařazeno 48 firem, což představuje podíl 81,44 %. Špatně bylo zařazeno 11 firem, což představuje podíl 18,56 %. Následným důležitým krokem je ověření, zda-li je klasifikační schopnost u testovacího vzorku dostatečná. Stejně jako u analyzovaného vzorku budou k ověření klasifikační schopnosti využity tři metody.

Pressova q-statistika diskriminační síly

Prvně je testována klasifikační schopnost pomocí Pressovy q-statistiky. Opět bude srovnávána již dříve uvedená kritická hodnota chi-kvadrátu s vypočtenou hodnotu q-statistiky. Výpočet dle vzorce (3.11) zobrazuje následující vztah:

$$q = \frac{(59 - 48 \cdot 2)^2}{59(2 - 1)} = 23,20.$$

Vypočtená hodnota q-statistiky je vyšší než hodnota kritická, proto lze klasifikační schopnost u testovacího vzorku považovat za dostatečnou.

Kritérium maximální věrohodnosti

Oproti analyzovanému vzorku byla v případě vzorku klasifikovaného nejpočetnější skupinou bankrotující skupina 1. Konkrétně se jednalo o 30 společností. Průběh výpočtu maximální věrohodnosti dle vzorce (3.12) zobrazuje následující výpočet:

$$h = (30 / 59) \cdot 100 = 50,85 \, \%.$$

Pomocí výpočtu kritéria maximální věrohodnosti bylo zjištěno, že klasifikační schopnost testovaného vzorku (81,35 %) je vyšší než minimální požadovaná klasifikační schopnost, která dosahuje hodnoty 50,85 %. Díky výše uvedeným faktům je možno považovat klasifikační schopnost za dostatečnou.

Kritérium poměrové pravděpodobnosti

Stejně jako u analyzovaného vzorku dat bude i v tomto případě využito kritérium poměrové pravděpodobnosti. Výpočet dle vzorce (3.13) zobrazuje následující vztah:

$$\pi = 0,51^2 + (1 - 0,51)^2 = 0,50.$$

I dle kritéria poměrové pravděpodobnosti lze dosaženou klasifikační sílu označit jako dostatečnou.

4.2.8 Fisherova diskriminační funkce

V rámci výpočtu diskriminační funkce v programu SPSS byla také získána Fisherova diskriminační funkce. Principem Fisherovy diskriminační funkce je vytvoření dvou rovnic, do kterých se vkládají data jednotlivých firem a dle dosaženého skóre je daná firma zařazena do skupiny číslo 0, nebo 1.

Tab. 4.7 Fisherova lineární diskriminační funkce

	Bankrot	
	0	1
ROA	-3,6903	-4,5208
FIN_PAK	-0,0429	-0,1299
DÚ_KZ	0,0001	0,0003
OA_CA	10,1723	11,6420
VEL	3,0866	2,7521
(Constant)	-20,1160	-17,9336

Zdroj: vlastní zpracování

Rozhodovacím kritériem je dosažení vyšší hodnoty u jednotlivých rovnic. Předcházející tabulka (Tab. 4.7) zobrazuje diskriminační koeficienty pro jednotlivé skupiny. Z výše uvedených koeficientů lze vytvořit diskriminační rovnice pro obě skupiny, které mají následující tvar:

$$Z_0 = -20,1160 - 3,6903 \cdot ROA - 0,0429 \cdot FIN_PAK + 0,0001 \cdot DÚ_KZ - \\ + 10,1723 \cdot OA_CA + 3,0866 \cdot VEL,$$

$$Z_1 = -17,9336 - 4,5208 \cdot ROA - 0,1299 \cdot FIN_PAK + 0,0003 \cdot DÚ_KZ - \\ + 11,6420 \cdot OA_CA + 2,7521 \cdot VEL.$$

Pomocí rovnic bylo v MS Excel vypočteno pro každou společnost skóre dle rovnice Z_0 a Z_1 . Zařazení do jednotlivých skupin shrnuje níže uvedená tabulka (Tab. 4.8).

Dle dosažených hodnot bylo zjištěno, že do skupiny 0 bylo správně zařazeno 25 firem, z celkového počtu 29. Tento poměr představuje podíl 86,21 %. Naopak nesprávně byly do skupiny 0 zařazeny 4 firmy, což v procentním vyjádření znamená 13,79 %.

Tab. 4.8 Predikce skupiny pomocí Fisherových diskriminačních koeficientů

skutečná skupina	Predikovaná skupina		Celkem
	0	1	
0	25	4	29
1	9	21	30
% podíl	86,21	13,79	100
% podíl	30,00	70,00	100

Zdroj: vlastní zpracování

U skupiny 1 bylo celkem hodnoceno 30 firem. Z tohoto celkového počtu bylo správně zařazeno 21 firem, což představuje podíl 70 %. Naopak nesprávně bylo mezi bankrotující firmy zařazeno 9 společností, což představuje poměr 30 %.

Celková klasifikační přesnost pomocí Fisherovy lineární diskriminační funkce činí 77,96 %. Při srovnání s přístupem, kdy byla ke klasifikaci využita pouze jedna rovnice, byly stejně klasifikovány všechny firmy ve skupině 0. Při srovnání obou metod u skupiny 1 došlo k mírnému zhoršení predikční schopnosti. Při využití Fisherových diskriminačních funkcí bylo špatně zařazeno 9 firem oproti 7 firmám při využití jedné diskriminační funkce. Celková predikční schopnost se snížila z 81,44 % na 77,97 %.

4.3 Logistická regrese

Cílem následující kapitoly je stanovení predikčního modelu finanční tísně na základě metody logistické regrese. Využita bude metoda binární logistické regrese, kdy vysvětlovaná proměnná může nabývat pouze dvou stavů. Jedna se o stav označený hodnotou 0, kdy dané společnosti nevykazují znaky finanční tísně a stav označený hodnotou 1, kdy se u daných analyzovaných firem objevily znaky, které jsou charakteristické pro společnosti ve finanční tísně.

Stejně jako u diskriminační analýzy budou využita data očištěného vzorku, který obsahuje 324 společností. Vzorek dat obsahuje 2 skupiny firem. První skupina obsahuje 209 firem bez znaků finanční tísně, druhá skupina obsahuje 115 firem, u kterých se v roce 2012 objevily znaky vedoucí k finanční tísně. K posouzení klasifikační schopnosti vytvořeného modelu bude využito klasifikovaného vzorku firem. Klasifikovaný vzorek čítá 59 firem, kdy u 29 z nich nebyly shledány znaky finanční tísně a naopak u 30 se tyto znaky vyskytovaly.

4.3.1 Vysvětlované a vysvětlující proměnné

V modelu logistické regrese se nacházejí dva typy proměnných. Jedná se o vysvětlované a vysvětlující proměnné. Vysvětlovaná proměnná může nabývat pouze dvou hodnot, a to hodnoty 0 a 1 v závislosti na bankrotní skupině. Jedná se tedy o dichotomickou proměnnou. Mezi vysvětlující proměnné jsou zařazeny jednotlivé ukazatele z oblastí rentability, aktivity, likvidity, zadluženosti a stability, které byly vypočítány dle vzorců (2.1) až (2.23).

Po stanovení jednotlivých nezávisle proměnných je potřeba určit, zda-li jsou statisticky významné pro predikci finanční tísně. Následující tabulka (Tab. 4.9) zobrazuje hodnoty významnosti jednotlivých nezávisle proměnných ve vztahu k závisle proměnné. Jelikož se v modelu pracuje s hodnotou významnosti 0,05, je potřeba pro další kroky vyřadit ukazatele, jejichž hodnota významnosti překročila stanovenou hranici.

Tab. 4.9 Významnost jednotlivých ukazatelů vůči proměnné bankrotu

ROA	ROCE	FIN_PAK	ROS	CEL_LIK	BEZ_LIK	OK_LIK	OB_AKT	DO_AKT
0,000	0,090	0,001	0,002	0,107	0,166	0,545	0,097	0,160
DS_POH	DÚ_KZ	VK_CA	OA_CA	CEL_ZAD	DL_ZAD	BE_ZAD	ÚR_ZAT	VEL
0,419	0,000	0,000	0,001	0,000	0,000	0,000	0,136	0,000

Zdroj: vlastní zpracování

Z důvodu překročení stanovené hranice významnosti nebude dále počítáno s rentabilitou dlouhodobých zdrojů, celkovou, běžnou a okamžitou likviditou, obratem aktiv, dobou obratu aktiv, dobou splatnosti pohledávek a úrokovým zatížením.

4.3.2 Multikolinearita

Jelikož bylo v tomto případě provedeno testování významnosti jednotlivých proměnných před hodnocením multikolinearity, není vhodné převzít hodnocení multikolinearity z kapitoly 4.2.1. Hodnota párové korelace mezi jednotlivými proměnnými je uvedena v příloze (Příloha 5). Prostřednictvím provedené analýzy byla zjištěna multikolinearita mezi rentabilitou aktiv a podílem vlastního kapitálu na celkových aktivech, celkovou zadlužeností a běžnou zadlužeností. Párová korelace vyšší než 0,8 byla dále zaznamenána mezi podílem vlastního kapitálu na celkových aktivech a celkovou a běžnou zadlužeností a také mezi celkovou a běžnou zadlužeností.

Díky existující silné závislosti mezi jednotlivými proměnnými bylo rozhodnuto o vyřazení jednotlivých ukazatelů. Konkrétně byla vyřazena rentabilita aktiv, podíl vlastního kapitálu na celkových aktivech a běžná zadluženost. V dalších krocích bude nadále pracováno s rentabilitou tržeb, finanční pákou, dobou úhrady krátkodobých závazků, podílem oběžných aktiv na celkových aktivech, celkovou a dlouhodobou zadlužeností a velikosti aktiv.

4.3.3 Kroková metoda

K vytvoření logistického modelu, stejně jako v případě diskriminační analýzy bude využito analytického programu PASW Statistcs 18. Jelikož je u analyzovaného vzorku dat možno dosáhnout pouze dvou stavů, bude využita funkce binární logistické regrese. Následně je možno zvolit typ logistické regrese. V tomto případě bylo využito metody Forward Stepwise. Na začátku je vytvořen prázdný model, u kterého je vypočtena míra regrese, a následně jsou v každém kroku přidávány jednotlivé proměnné. V případě, že se naopak určitá proměnná stane v průběhu výpočtu nevýznamná, je z modelu vyřazena. V rámci metody se také sleduje hodnota Waldovy statistiky.

V níže zobrazené tabulce (Tab. 4.10) je uvedena míra těsnosti proložením logistickým modelem v nultém kroku. Nultý krok představuje takový model, ve kterém nejsou zařazeny žádné proměnné. Po třech iteracích bylo dosaženo hodnoty 421,492. Jak je z tabulky patrné k dalším iteracím již nedošlo, protože změna mezi 2. a 3. iterací je menší než 0,001.

Tab. 4.10 Charakteristika modelu v nultém kroku

Iterace		-2Log likelihood	Koeficienty
			Konstanta
Step 0	1	421,514	-0,580
	2	421,492	-0,597
	3	421,492	-0,597

Zdroj: vlastní zpracování

Následujícím krokem Stepwise metody je postupné přidávání jednotlivých nezávislých proměnných do logistického modelu a snaha o snížení míry těsnosti proložením logistickým modelem. Rozhodujícím kritériem je maximalizace hodnoty skóre a dodržení požadované významnosti. Následující tabulka (Tab. 4.11) shrnuje výběr jednotlivých proměnných do modelu logistické regrese. Podrobný výběr nezávislých proměnných a jednotlivé charakteristiky obsahuje příloha (Příloha 6).

Tab. 4.11 Souhrnná tabulka jednotlivých kroků Stepwise metody

Krok	Proměnná	Skóre	df	Významnost
0	VEL	60,796	1	0,000
1	CEL_ZAD	19,191	1	0,000
2	DL_ZAD	11,914	1	0,001
3	ROS	11,101	1	0,001
4	DÚ_KZ	6,775	1	0,009
5	OA_CA	5,102	1	0,024
6	FIN_PAK	0,031	1	0,860

Zdroj: vlastní zpracování

Jak je z dosažených výsledku patrné, na základě dosažení hodnoty skóre v jednotlivých krocích a dodržení hladiny významnosti 0,05, byly do logistického modelu zařazeny ukazatele celkové a dlouhodobé zadluženosti, rentability tržeb, doby úhrady krátkodobých závazků, podílů oběžných aktiv na celkových aktivech a velikost aktiv. Do logistického modelu naopak nebyl zařazen ukazatel finanční páky. Jak je patrné z přílohy (Příloha 6), ukazatel finanční páky v nultém kroku splňoval jak podmínku významnosti, tak i poměrně vysokou hodnotu skóre. Při průběžném zařazování proměnných do modelu a přepočítávání jednotlivých charakteristik se stal ukazatel finanční páky statisticky

nevýznamný. Také hodnota dosaženého skóre tohoto ukazatele se pohybuje na velmi nízkých hodnotách. Z výše uvedených důvodů nebude ukazatel finanční páky do modelu zařazen.

4.3.4 *Odhad logistického modelu*

Dalším krokem je sestavení logistické funkce, pomocí které budou následně jednotlivé firmy zařazovány do určité bankrotní skupiny. V příloze (Příloha 7) jsou zobrazeny charakteristiky proměnných, které byly zařazeny do modelu. Z dosažených hodnot je patrné, že v 6. kroku se na základě kritéria Waldovy statistiky staly nevýznamnými ukazatele doby úhrady krátkodobých závazků a velikosti aktiv. Jelikož však tyto ukazatele ve spojení se zbývajících proměnnými přispívají ke zlepšení regrese, budou v modelu ponechány.

Logistická funkce bude sestavena z jednotlivých koeficientů, které byly do modelu zařazeny až po 6. krok. Jedná se tedy o rentabilitu tržeb, dobu úhrady krátkodobých závazků, podíl oběžných aktiv na celkových aktivech, celkovou a dlouhodobou zadluženost a velikost aktiv. Důležitou položkou v tabulce (Příloha 7) je hodnota beta, která je označena jako B. Tato hodnota udává koeficienty jednotlivých nezávislých proměnných. Po dosazení jednotlivých koeficientů do rovnice (3.15) je možno vyjádřit logistický model, který má následující tvar:

$$\pi(x) = \frac{e^{-1,7272-1,9986 \cdot ROS+0,0002 \cdot DÚ_KZ+1,3677 \cdot OA_CA+2,5613 \cdot CEL_ZAD-2,0429 \cdot DL_ZAD+0,1490 \cdot VEL}}{1+e^{-1,7272-1,9986 \cdot ROS+0,0002 \cdot DÚ_KZ+1,3677 \cdot OA_CA+2,5613 \cdot CEL_ZAD-2,0429 \cdot DL_ZAD-0,1489 \cdot VEL}} \cdot$$

Pomocí transformační rovnice uvedené v rovnici (3.16) je možno vytvořit logit, který má následující tvar:

$$g(x) = -1,7272 - 1,9986 \cdot ROS + 0,0002 \cdot DÚ_KZ + 1,3677 \cdot OA_CA + \\ + 2,5613 \cdot CEL_ZAD - 2,0429 \cdot DL_ZAD + 0,1490 \cdot VEL.$$

4.3.5 *Ověření správnosti modelu*

K ověření vytvořeného modelu je možno využít změnu míry těsnosti proložením logistickým modelem (-2LL), Cox & Snell R Square a Nagelkerke R Square. Charakteristiky v jednotlivých krocích daných statistik jsou uvedeny v následující tabulce.

Tab. 4.12 Vývoj míry těsnosti, Cox & Snell a Nagelkerkeho statistika

Step	-2 Log likelihood	Cox & Snell R Square	Nagelkerke R Square
1	353,496	0,189	0,260
2	283,352	0,347	0,477
3	271,603	0,370	0,509
4	255,879	0,400	0,550
5	252,201	0,407	0,559
6	247,039	0,416	0,572

Zdroj: vlastní zpracování

Dle dosažených hodnot lze konstatovat, že postupným přidáváním nezávislých proměnných do logistického modelu v 1. až 6. kroku došlo k výraznému snížení míry těsnosti -2LL. Pozitivně lze hodnotit, že původní hodnoty 421,492, která byla dosažena v nultém kroku, tedy v modelu bez nezávislých proměnných bylo postupným dosazováním proměnných v jednotlivých krocích dosaženo výrazného snížení až na hodnotu 247,039.

Vypovídací schopnost vytvořeného logistického modelu také uvádí Cox & Snell a Nagelkerke statistika. Jelikož není možno u Cox & Snell R Square dosáhnout hodnoty 1, je vhodnější využít Nagelkerke R Square. Pomocí Nagelkerke R Square lze konstatovat, že závislá proměnná (bankrot) je prostřednictvím nezávislých proměnných vysvětlována na 57,2 %.

4.3.6 Poměr šancí (*odds ratio*)

Pro správně využití odhadnutého modelu je důležitá jeho interpretace. Jednotlivé koeficienty lze interpretovat pomocí poměru šancí. Pokud je hodnota poměru šancí $\exp(B_k)$ menší než jedna, daná proměnná přispívá ke snížení hodnoty závisle proměnné. Pokud je naopak hodnota poměru šancí vyšší než jedna, ukazatel pozitivně přispívá k hodnotě závisle proměnné, neboli zvyšuje se šance existence určitého jevu. Následující tabulka (Tab. 4.13) zobrazuje výpočet poměru šancí dle vzorce (3.22). Podrobný výpočet jednotlivých hodnot je zobrazen v příloze (Příloha 8).

Tab. 4.13 Výpočet poměru šancí

	VEL	DL_ZAD	CEL_ZAD	OA_CA	DÚ_KZ	ROS
$\pi(P_0)$	0,178	0,178	0,178	0,178	0,178	0,178
$\pi(P_1)$	0,153	0,023	2,303	0,698	0,178	0,024
$\exp(\beta_k)$	0,862	0,130	12,949	3,927	1,000	0,135

Zdroj: vlastní zpracování

Z dosažených hodnot uvedených v předešlé tabulce vyplývá, že ke snížení šance vzniku bankrotu přispívají ukazatele dlouhodobé zadluženosti, rentability tržeb a velikosti aktiv, neboť hodnota $\exp(\beta_k)$ je menší než 1. Dojde-li ke zvýšení ukazatele velikosti aktiv o jednotku, dojde ke zvýšení šance bankrotu o 0,862. Růstem objemu celkových aktiv se snižuje šance ke vzniku bankrotu, neboť firma se stává kapitálově silnější. Při růstu rentability tržeb se zvyšuje šance vzniku bankrotu o 0,135. Dochází tak ke snížení šance bankrotu, neboť při růstu ukazatele rentability dokáže podnik vydělávat více čistého zisku na jednu jednotku tržeb. Při růstu dlouhodobé zadluženosti o jednotku dochází ke zvýšení bankrotu o 0,130. Lze tedy říci, že pomocí dlouhodobého zadlužení lze snížit šanci na existenci bankrotu, oproti jiným formám zadlužení. U doby úhrady krátkodobých závazků je patrné, že šance pro vznik bankrotu je při zvýšení tohoto ukazatele minimální, což odpovídá i hodnotě v logistickém modelu, kdy na změnu závislé proměnné přispívá ukazatel hodnotou 0,0002.

Naopak ke zvýšení šance, že u sledovaných firem dojde k bankrotu, přispívají ukazatele celkové zadluženosti a podílu oběžných aktiv na celkových aktivech. Pokud dojde ke zvýšení celkové zadluženosti o jednotku, je 12,9499 násobná šance, že u dané firmy dojde k bankrotu. V případě, že dojde ke zvýšení ukazatele podílu oběžných aktiv na celkových aktivech o jednu jednotku, je 3,927 násobně vyšší šance, že firma se objeví ve skupině bankrotujících firem, neboť oběžná aktiva se ve společnostech nacházejí krátkou dobu a tudíž nemohou vytvářet takovou hodnotu jako aktiva stálá.

4.3.7 Klasifikační matice analyzovaného vzorku dat

Následující část kapitoly ověřuje klasifikační schopnost vytvořeného logistického modelu. Jelikož logistický model celkově obsahuje 6 nezávisle proměnných, byla klasifikační schopnost ověřována po přidání každé proměnné. Níže uvedená tabulka (Tab. 4.14) zobrazuje zpětné zařazení jednotlivých dat analyzovaného vzorku do dané bankrotní skupiny v posledním 6. kroku. Vývoj zpětného zařazení v jednotlivých krocích je zobrazen v příloze (Příloha 9).

Tab. 4.14 Klasifikační matice vstupního vzorku v 6. kroku

Skutečná skupina	Predikovaná skupina		Celkem
	0	1	
0	194	15	209
1	42	73	115
% podíl	92,82	7,18	100
% podíl	36,52	63,48	100

Zdroj: vlastní zpracování

První řádek zobrazuje skupinu 0, tj. skupina firem, u které se v roce 2012 neobjevovaly znaky finanční tísně. Celkově tato skupina obsahuje data 209 firem, což z celkového počtu analyzovaných dat představuje 64,51 %. Z tohoto počtu bylo správně dle logistického modelu mezi skupinu 0 zařazeno 194 společností. V procentním vyjádření tato hodnota představuje 92,82 %. Naopak nesprávně bylo do první skupiny zařazeno 15 firem z celkového počtu 209. Tento počet představuje podíl 7,18 %.

Druhý řádek zobrazuje skupinu firem, u kterých se objevovaly znaky vedoucí k finanční tísně. Tato skupina je označena hodnotu 1. Skupina 1 obsahuje 115 firem z celkového počtu analyzovaného vzorku dat, což představuje podíl 35,49 %. Z tohoto počtu bylo správně mezi skupinu 1 predikováno 73 firem, což představuje podíl ve výši 63,48 %. Naopak nesprávně byla dle logistického modelu predikována skupina u 42 společností. V procentním vyjádření byla nesprávně predikována skupina u 36,52 %.

Pomocí jednotlivých dosažených hodnot lze také hodnotit výslednou klasifikační schopnost daného logistického modelu. Z celkového počtu 324 společností bylo správně zařazeno 267 společností. Naopak nesprávně bylo zařazeno 57 společností. V procentním vyjádření se jedná o správnou klasifikační schopnost ve výši 82,41 %. Z dosažených výsledků je patrné, že vytvořený logistický model dokáže poměrně přesně klasifikovat bankrotní skupinu u firem bez finanční tísně, naopak méně kvalitně dokáže predikovat bankrotní skupinu u firem se znaky finanční tísně. Následně je důležité ověřit, zda-li je dosažená klasifikační schopnost dostatečná pro následné využití u testovacího vzorku dat. K tomuto ověření bude využita metoda maximální věrohodnosti, poměrové pravděpodobnosti a grafické znázornění pomocí ROC křivky.

Kritérium maximální věrohodnosti

V případě kritéria maximální věrohodnosti ověřujeme, zda-li je klasifikační schopnost daného modelu dostatečná v poměru s procentním zastoupením nejpočetnější skupiny v analyzovaném vzorku. V našem případě se jedná o skupinu 0. V následující rovnici je zobrazen průběh výpočtu této hodnoty dle vzorce (3.12):

$$h = (209 / 324) \cdot 100 = 64,05 \ %.$$

Dle výpočtu je minimální požadována hodnota kritéria maximální věrohodnosti 64,05 %. Jelikož je dosažená klasifikační schopnost analyzovaného vzorku ve výši 82,41 %, je model vhodný pro následnou analýzu klasifikovaného vzorku dat.

Kritérium poměrové pravděpodobnosti

Další metodou pro ověření klasifikační schopnosti je kritérium poměrové pravděpodobnosti. Kritérium poměrové pravděpodobnosti porovnává procentní zastoupení jednotlivých testovaných skupin na celkovém vzorku a srovnává ji s dosaženou klasifikační schopností logistického modelu. Jak již bylo dříve zmíněno, skupina 0 zaujímá 64,51 %, zbývajících 35,49 % představují skupinu 1. Výpočet kritéria poměrové pravděpodobnosti dle vzorce (3.13) shrnuje následující vztah:


$$\pi = (0,65)^2 + (1 - 0,65)^2 = 54,50 \ %.$$

Jelikož je minimálně požadovaná hodnota kritéria poměrové pravděpodobnosti nižší, než skutečně dosažená hodnota, je i dle tohoto testu klasifikační schopnost dostatečná. Pro úplnost testu je vhodné navýšit dosaženou hodnotu u kritéria poměrové pravděpodobnosti o 25 %. Při navýšení kritéria o 25 % je výsledná hodnota 68,13 %. I při navýšení kritéria o 25 % je model vytvořený metodou logistické regrese stále vhodný pro následnou predikci u testovaného vzorku dat z důvodu nižší minimálně požadované hodnoty než je skutečná klasifikační schopnost modelu, tj. 82,41 %.

ROC křivka

Dalším nástrojem pro ověření vhodnosti vytvořeného modelu k následné predikci je využití ROC křivky. Následující graf (Graf 4.2) zobrazuje vývoj ROC křivky, kdy je sledován vztah mezi senzitivitou a specificitou analyzovaného vzorku dat.

Graf 4.2 Vývoj ROC křivky



Jak je patrné z grafu, křivka ROC se výrazně přibližuje k levému hornímu rohu, což znamená, že je dosažena vysoká predikční spolehlivost vytvořeného modelu. Skutečnost, že vytvořený model je vhodný k predikci finanční tísně, byla potvrzena i hodnotou plochy pod křivkou ROC. V tomto případě byla zjištěna hodnota plochy pod ROC křivkou ve výši 0,896. Dosažená hodnota plochy pod ROC křivkou se pohybuje v intervalu od 0,8 do 0,9, lze tedy tuto hodnotu považovat za dobrou.

4.3.8 Klasifikační matice klasifikovaného vzorku dat

Jelikož byla prostřednictvím jednotlivých statistických testů zjištěna dostatečná klasifikační schopnost vytvořeného logistického modelu, bude v následující části model aplikován na klasifikovaný vzorek dat. Ověření klasifikační schopnosti a přiřazení firem do jednotlivých skupin bylo provedeno pomocí programu MS EXCEL. Hodnoty proměnných jednotlivých firem byly zařazovány do vytvořené logistické rovnice. Výsledné hodnoty se pohybují v intervalu $<0;1>$, kdy hraniční bod pro přiřazení do skupin je určen hodnotou 0,5. Následující tabulka (Tab. 4.15) zobrazuje predikci bankrotní skupiny u testovacího vzorku dat. Testovací vzorek celkem obsahuje 59 společností. Skupinu firem bez znaků finanční tísně tvoří 29 společností, zbylých 30 firem představují společnosti, u kterých byla v roce 2012 zaznamenána finanční tíseň.

Tab. 4.15 Klasifikační matice testovaného vzorku

Skutečná skupina	Predikovaná skupina		Celkem
	0	1	
0	26	3	29
1	13	17	30
% podíl	89,66	10,34	100
% podíl	43,33	56,67	100

Zdroj: vlastní zpracování

První řádek je opět věnován nebankrotující skupině 0. Z dosažených výsledků je patrné, že z celkových 29 společností byla správně predikována bankrotující skupina u 26 firem. Tato hodnota odpovídá procentnímu podílu ve výši 89,66 %. Nesprávně byla bankrotující skupina predikována pro 3 společnosti. Z celkového počtu 29 firem je jedná o procentní podíl ve výši 10,34 %.

Predikční schopnost u firem se znaky finanční tísně v roce 2012 zobrazuje druhý řádek. Z dosažených výsledků je patrné, že z celkového počtu 30 firem bylo správně mezi skupinu 1 zařazeno 17 firem. Tento počet v procentním vyjádření představuje 56,67 %. Nesprávně byla predikována bankrotní skupina u 13 firem. Z celkového počtu 30 firem bylo nesprávně zařazeno 43,33 % firem. Je patrné, že i u testovaného vzorku dat došlo ke stejnému jevu jako u vzorku analyzovaných dat a to, že byla zjištěna zhoršená predikční schopnost u firem skupiny se znaky finanční tísně.

Pomocí klasifikační matice testovaného vzorku lze ověřit také celkovou klasifikační schopnost vytvořeného logistického modelu. Z celkového počtu 59 firem byla správně predikována bankrotní skupina u 43 firem, což představuje procentní podíl ve výši 72,88 %. Naopak nesprávně byla bankrotní skupina predikována u 16 firem. Tato hodnota představuje procentní podíl ve výši 27,19 %. V následujícím kroku je potřeba ověřit, zda-li je dosažená klasifikační schopnost dostatečná v souvislosti s procentním zastoupením jednotlivých bankrotních skupin v testovaném vzorku. Ověření bude provedeno opět pomocí kritéria maximální věrohodnosti a poměrové pravděpodobnosti.

Kritérium maximální věrohodnosti

Kritérium maximální věrohodnosti porovnává predikční schopnost s procentním zastoupením nejpočetnější skupiny ve vzorku dat. V tomto případě představuje nejpočetnější

zastoupení bankrotní skupina 1 s 30 firmami. Hodnotu kritéria a výpočet dle vzorce (3.12) lze znázornit níže uvedeným vztahem:

$$h = (30 / 59) \cdot 100 = 50,85 \ %.$$

Minimálně požadována klasifikační schopnost vytvořeného logistického modelu je nižší než skutečně dosažená hodnota, tj. 72,88 %. Prostřednictvím kritéria maximální věrohodnosti lze považovat dosaženou klasifikační přesnost za dostatečnou.

Kritérium poměrové pravděpodobnosti

Kritérium poměrové pravděpodobnosti porovnává procentní zastoupení jednotlivých bankrotních skupin na celkovém vzorku dat s celkovou predikční přesností modelu. Výpočet kritéria dle vzorce (3.13) je znázorněn následujícím vztahem:

$$\pi = (0,51)^2 + (1 - 0,51)^2 = 50,02 \ %.$$

Dle dosažených hodnot lze konstatovat, že predikční schopnost je dostatečná, neboť minimálně požadována míra klasifikační přesnosti je nižší než skutečně dosažená klasifikační schopnost modelu, která dosahuje výše 72,88 %. Stejně jako u analyzovaného vzorku dat, i v tomto případě bude kritérium navýšeno o 25 %. Při navýšení kritéria o 25 % je dosaženo hodnoty 62,52 %. I v tomto případě je klasifikační schopnost dostatečná a model je tudíž vhodný k predikci finanční tísně.

4.3.9 Klasifikační schopnost při zavedení šedé zóny

Častým jevem u jednotlivých bankrotních a bonitních modelů je existence tzv. šedé zóny. Cílem šedé zóny je zmírnění ostré hranice mezi dvěma skupinami. Pomocí metody logistické regrese je možno získat hodnoty v intervalu $\langle 0;1 \rangle$. Při hodnotě nižší než 0,4 je daná společnost zařazena do bankrotní skupiny 0. V případě hodnoty vyšší než 0,6 se jedná o bankrotní skupinu 1. Pokud se vypočtená hodnota pohybuje v intervalu $\langle 0,4;0,6 \rangle$ je společnost zařazena do šedé zóny.

Níže uvedená tabulka (Tab. 4.16) zobrazuje klasifikační schopnost při vytvoření kategorie šedé zóny. Z dosažených výsledků je patrné, že při zavedení šedé zóny bylo správně predikováno 42 společností, což představuje podíl 71,19 %. Chybně bylo predikováno 13 společností s podílem 22,03 %. Do kategorie šedé zóny byly zařazeny 4 společnosti, což představuje podíl 6,78 %. Ve srovnání s klasifikační maticí, která obsahuje pouze dvě

kategorie, lze v tomto případě sledovat snížení chybně predikovaných společností. Do šedé zóny byly zařazeny 3 firmy z chybné predikce a jedna firma ze správně určené predikce.

Tab. 4.16 Klasifikační matice při existenci tzv. šedé zóny

Hranice	Skupina 0	Skupina 1		Predikce	Počet	% podíl
0 – 0,4	25	10		správně	42	71,19
0,4 – 0,6	1	3		šedá zóna	4	6,78
0,6 – 1,0	3	17		chybně	13	22,03

Zdroj: vlastní zpracování

4.4 Srovnání vytvořených modelů

Následující tabulka (Tab. 4.17) souhrnně zobrazuje charakteristiky jednotlivých predikčních modelů vytvořených pomocí diskriminační analýzy a logistické regrese.

Tab. 4.17 Srovnání modelů

	Diskriminační analýza	Logistická regrese
Proměnné obsažené v modelu	ROA, FIN_PAK, DÚ_KZ, OA_CA, VEL	ROS, DÚ_KZ, OA_CA, CEL_ZAD, DL_ZAD, VEL
Klasifikační schopnost dle analyzovaného vzorku	79,93 %	82,06 %
Klasifikační schopnost dle testovacího vzorku	81,35 %	72,88 %

Zdroj: vlastní zpracování

Dle výše uvedené tabulky je patrné, že v případě diskriminační analýzy byly do modelu zařazeny ukazatele rentability aktiv, finanční páky, doby úhrady krátkodobých závazků, podílu oběžných aktiv na celkových aktivech a velikost aktiv. V případě logistické regrese ukazatele rentability tržeb, doby úhrady krátkodobých závazků, podílu oběžných aktiv na celkových aktivech, velikosti aktiv, celkové a dlouhodobé zadluženosti. V případě obou modelů byly tedy shodně zařazeny ukazatele doby úhrady krátkodobých závazků, podílu oběžných aktiv na celkových aktivech a velikost aktiv. Dále lze konstatovat, že pomocí metody logistické regrese bylo dosaženo vyšší predikční schopnosti o 2,13 p.b. u analyzovaného vzorku dat oproti metodě diskriminační analýzy. Avšak v případě testovaného vzorku dat došlo u metody logistické regrese ke zhoršené predikční schopnosti oproti diskriminační analýze o 8,47 p.b.

5 Závěr

Cílem této diplomové práce byl odhad predikčních modelů finanční tísně. Jednotlivé modely byly odhadnuty na základě finančních výkazů 429 obchodních společností působících na území České republiky. Finanční výkazy společností za účetní období roku 2011 byly shromážděny a zpracovány prostřednictvím Obchodního rejstříku a aplikace MagnusWeb společnosti Čekia. Z celkového počtu 429 firem jich bylo 249 zařazeno mezi skupinu finančně zdravých firem, druhou skupinu tvořilo 180 firem, u kterých byly v roce 2012 dle insolvenčního rejstříku zaznamenány znaky finanční tísně. Za takovéto znaky byly považovány např. vyhlášení úpadku, likvidace, konkurzu nebo zahájení insolvenčního řízení na návrh věřitele či dlužníka.

Na finanční výkazy jednotlivých firem byla aplikována finanční analýza, kdy se prostřednictvím 23 poměrových ukazatelů sledovala oblast rentability, aktivity, likvidity, stability a zadluženosti. Po dalších úpravách a posouzení multikolinearity bylo vybráno 13 finančních ukazatelů, které byly použity k odhadu modelů. Analyzovaný soubor dat, na základě kterého byly modely odhadovány, obsahuje celkem 324 firem. Následně byly modely ověřovány na klasifikovaném vzorku dat, který obsahuje finanční výkazy 59 firem.

Vybrané finanční ukazatele byly použity jako vstupní údaje pro tvorbu predikčních modelů. K odhadu predikčních modelů bylo využito statistického programu PASW Statistics 18. První model byl vytvořen na základě metody diskriminační analýzy, druhý prostřednictvím metody logistické regrese. Firmy byly rozděleny do dvou skupin, podle existence znaků finanční tísně. Do první skupiny, označené hodnotou 0, byly zařazeny společnosti bez znaků finanční tísně. Do druhé skupiny, označené hodnotou 1, byly zařazeny společnosti, které v roce 2012 vykazovaly znaky finanční tísně.

Po odhadu jednotlivých modelů bylo zjištěno, že u metody diskriminační analýzy byly jako diskriminátory vybrány ukazatele rentability aktiv, finanční páky, doby úhrady krátkodobých závazků, podílu oběžných aktiv na celkových aktivech a velikost aktiv. Prostřednictvím metody logistické regrese byly jako regresní koeficienty vybrány ukazatele rentability tržeb, doby úhrady krátkodobých závazků, podílu oběžných aktiv na celkových aktivech, celkové a dlouhodobé zadluženosti a velikost aktiv. Z dosažených výsledků je patrné, že v případě obou metod byly do predikčních modelů jako významné indikátory zařazeny ukazatele podílu oběžných aktiv na celkových aktivech, doby úhrady krátkodobých závazků a velikost aktiv.

Po odvození jednotlivých modelů následovalo ověření jejich predikční síly. Predikční síla byla zpětně testována na analyzovaném i na klasifikovaném vzorku dat, který byl vyčleněn z výběrového souboru. U diskriminační analýzy bylo dosaženo klasifikační schopnosti u analyzovaného vzorku dat 79,93 %, u klasifikačního vzorku dat byla dosažena klasifikační schopnost 81,35 %. V obou případech byla klasifikační síla dle provedených testů shledána jako dostatečná. V případě metody logistické regrese bylo dosaženo u analyzovaného vzorku dat predikční síly 82,06 %, u klasifikovaného vzorku dat bylo dosaženo úspěšné predikce ve výši 72,88 %. Také v případě metody logistické regrese byla zjištěná klasifikační síla dle provedených testů shledána jako dostatečná. Dostatečná klasifikační síla byla v případě metody logistické regrese také potvrzena ROC křivkou, která se blížila levému hornímu rohu a hodnota plochy pod křivkou činila 0,89.

Na základě výše uvedených důvodů lze konstatovat, že modely stanovené pomocí metody diskriminační analýzy a logistické regrese jsou vhodné pro predikci finanční tísně a mohou tak sloužit k rychlému ověření finančního zdraví podniků. Vyšší predikční síly bylo v případě klasifikovaného vzorku dat dosaženo u metody diskriminační analýzy. Stanovené modely je možno využít v oblasti bankovníctví a obchodních vztahů pro ověření potenciálních dlužníků resp. obchodních partnerů. Je však důležité podotknout, že modely je potřeba využívat v souvislosti s dalšími metodami komplexního hodnocení podniků, neboť na žádný model se nelze stoprocentně spolehnout.

Seznam použité literatury

- [1] DLUHOŠOVÁ, Dana. *Finanční řízení a rozhodování podniku: analýza, investování, oceňování, riziko, flexibilita*. 2. vyd. Praha: Ekopress, 2008. 192 s. ISBN 978-80-86929-44-6.
- [2] FIELD, Andy P. *Discovering statistics using SPSS: (and sex, drugs and rock 'n' roll)*. 3rd ed. Los Angeles: SAGE Publications, 2009. 821 s. ISBN 978-1-84787-906-6.
- [3] FOTR, Jiří a Ivan SOUČEK. *Podnikatelský záměr a investiční rozhodování*. 1. vyd. Praha: Grada, 2005. 356 s. ISBN 80-247-0939-2.
- [4] HAIR, Joseph F. *Multivariate data analysis*. 5th ed. New Jersey: Prentice-Hall International, 1998. 730 s. ISBN 01-393-0587-4.
- [5] HAIR, Joseph F. *Multivariate data analysis*. 7th ed. New Jersey: Prentice-Hall International, 2009. 816 s. ISBN 01-381-3263-1.
- [6] HANČLOVÁ, Jana. *Ekonometrické modelování: klasické přístupy s aplikacemi*. 1. vyd. Praha: Professional Publishing, 2012. 214 s. ISBN 978-80-7431-088-1.
- [7] HENDL, Jan. *Přehled statistických metod: analýza a metaanalýza dat*. 3. vyd. Praha: Portál, 2009. 695 s. ISBN 978-80-7367-482-3
- [8] HOSMER, David W. a Stanley LEMESHOW. *Applied logistic regression*. 2nd ed. New York: Wiley, 2000. 375 p. ISBN 0-471-35632-8.
- [9] KISLINGEROVÁ, Eva. *Finanční analýza: krok za krokem*. Praha: C. H. Beck, 2005. 137 s. ISBN 80-717-9321-3.
- [10] KUBÁNOVÁ, Jana. *Statistické metody pro ekonomickou a technickou praxi*. 1. vyd. Bratislava: Statis, 2003. 247 s. ISBN 978-8085-5931-3.
- [11] LÖFFLER, Gunter a Peter N. POSCH. *Credit risk modeling using Excel and VBA*. 1st ed. Chichester: Wiley, 2007. 261 p. ISBN 978-0-470-03157-5.
- [12] MARINIČ, Pavel. *Plánování a tvorba hodnoty firmy*. 1. vyd. Praha: Grada, 2008. 232 s. ISBN 978-80-247-2432-4.
- [13] MELOUN, Milan a Jiří MILITKÝ. *Kompedium statistického zpracování dat: metody a řešené úlohy*. 2. vyd. Praha: Academia, 2006. 982 s. ISBN 80-200-1396-2.

- [14]MELOUN, Milan a Jiří MILITKÝ. *Statistická analýza experimentálních dat*. 2. vyd. Praha: Academia, 2004. 953 s. ISBN 80-200-1254-0.
- [15]RŮČKOVÁ, Petra. *Finanční analýza: metody, ukazatele, využití v praxi*. 2. vyd. Praha: Grada, 2008. 120 s. ISBN 978-80-247-2482-2.
- [16]RŮČKOVÁ, Petra. *Finanční analýza: metody, ukazatele, využití v praxi*. 3. vyd. Praha: Grada, 2010. 139 s. ISBN 978-80-247-3308-1.
- [17]SEDLÁČEK, Jaroslav. *Účetní data v rukou manažera: finanční analýza v řízení firmy*. 2. vyd. Praha: Computer Press, 2001. 220 s. ISBN 80-722-6562-8.
- [18]SMEJKAL, Vladimír. *Řízení rizik ve firmách a jiných organizacích*. 3. vyd. Praha: Grada, 2010. 354 s. ISBN 978-80-247-3051-6.
- [19]SYNEK, Miloslav. *Manažerská ekonomika: metody, ukazatele, využití v praxi*. 1. vyd. Praha: Grada, 1996. 455 s. ISBN 80-716-9211-5.
- [20]TRČKA, Aleš. *Analýza rentability společnosti v dřevařském průmyslu*. Ostrava, 2011. Bakalářská práce. Vysoká škola Báňská – Technická univerzita Ostrava, Fakulta ekonomická, Katedra financí.
- [21]VOCHOZKA, Marek. *Metody komplexního hodnocení podniku*. 1. vyd. Praha: Grada, 2011. 246 s. ISBN 978-80-247-3647-1.
- [22]ZVÁRA, Karel. *Regresní analýza: klasické přístupy s aplikacemi*. 1. vyd. Praha: Academia, 1989. 245s. ISBN 80-200-0125-5.

Internetové zdroje

- [23]ALTMAN, Edward I. *Predicting financial distress of companies: Revisiting the Z-Score and ZETA models*. [online]. 2000, s. 54 [cit. 2013-02-10]. Dostupné z: <http://pages.stern.nyu.edu/~ealtman/Zscores.pdf>.
- [24]BRIŠ, Radim a Martina LITSCHMANNOVÁ. *Statistika I.: pro kombinované a distanční studium* [online]. 2004 [cit. 2013-03-02]. Dostupné z: <http://home1.vsb.cz/~bri10/Teaching/Statistika%201/>.

- [25]CZECH CREDIT BUREAU. *Skóringové modely* [online]. 2013 [cit. 2013-03-05]. Dostupné z: <http://www.crif.cz/%C5%98e%C5%A1en%C3%AD/Produkty/Pages/Scoringov%C3%A9-modely.aspx>.
- [26]ČEKIA. *MagnusWeb* [online]. [cit. 2013-02-08]. Dostupné z: <http://www.cekia.cz/magnusweb/>.
- [27]ČEKIA: *Loni vzniklo nejméně firem za posledních pět let.* [online]. 2012. [cit. 2013-02-07]. Dostupné z: <http://www.cekia.cz/cz/archiv-tiskovych-zprav/315-tz120116>.
- [28]JAKUBÍK, Petr a Petr TEPLÝ. *Skóring jako indikátor finanční stability*. In: Zpráva o finanční stabilitě [2007]. Praha: Česká národní banka, 2007, s. 76-85. ISBN 978-80-87225028. Dostupné z: http://www.cnb.cz/miranda2/export/sites/www.cnb.cz/cs/financni_stabilita/zpravy_fs/fs_2007/FS_2007.pdf.
- [29]MELOUN, Milan. *Chemometrie II - Vícerozměrná data* [online]. [cit. 2013-02-12]. Dostupné z: meloun.upce.cz/vyuka/chemometrie-ii.
- [30]MINISTERSTVO SPRAVEDLNOSTI ČESKÉ REPUBLIKY [online]. 2013 [cit. 2011-02-08]. *Insolvenční rejstřík*. Dostupné z: <https://isir.justice.cz/isir/common/index.do>.
- [31]MINISTERSTVO SPRAVEDLNOSTI ČESKÉ REPUBLIKY [online]. 2013 [cit. 2011-02-02]. *Obchodní rejstřík*. Dostupné z: <https://or.justice.cz/ias/ui/rejstrik-rozsirene>.
- [32]NEUMAIER, Ivan a Inka NEUMAIEROVÁ. *Index IN05*. In: Evropské finanční systémy. 2005. vyd. Brno: Masarykova univerzita v Brně, 2005, s. 143-148. ISBN 80-210-3753-9. Dostupné z: <http://is.muni.cz/do/1456/sborniky/2005/evropske-financni-systemy-2005.pdf>.
- [33]PECÁKOVÁ, Iva. *Logistická regrese s vícekategoriální vysvětlovanou proměnnou*. In: Acta oeconomica Pragensia: Vědecký sborník Vysoké školy ekonomické v Praze. Praha: Vysoká škola ekonomická, 2007, s. 86-96. ISSN 0572-3043. Dostupné z: www.vse.cz/polek/download.php?jnl=aop&pdf=42.pdf.
- [34]ROST, Michael. *Metody shlukové analýzy*. [online]. 2011 [cit. 2013-03-23]. Dostupné z: ccv.ef.jcu.cz/opvkreg/prezentace/okruh8/pre8tema-10-Slidy_pro_shlukovou_analyzu_OPVK_Rost.pdf.

- [35]TROJAN, Filip. *Využití statistických metod v bankovníctví*. In: ROBUST 2002: sborník prací dvanácté zimní školy JČMF. V Praze: Jednota českých matematiků a fyziků, 2002, s. 315-320. ISBN 80-7015-900-6. Dostupné z: www.statapol.cz/robust/#02.
- [36] Zákon č. 182/2006 Sb., o úpadku a způsobech jeho řešení. In: Sbírka zákonů České republiky. 2006. Dostupné z: <http://business.center.cz/business/pravo/zakony/insolvenční/>.
- [37]VYSOKÁ ŠKOLA EKONOMICKÁ. *Multikolinearita* [online]. 2013 [cit. 2013-03-23]. Dostupné z: <http://nb.vse.cz/~zouharj/zek/multikolinearita.pdf>.
- [38]VYSOKÁ ŠKOLA EKONOMICKÁ. *Typy proměnných* [online]. 2013 [cit. 2013-03-01]. Dostupné z: http://iastat.vse.cz/typy_promennych.html.

Seznam zkratek

AUC	plocha pod křivkou
BE_ZAD	běžná zadluženost
BEZ_LIK	běžná likvidita
CEL_LIK	celková likvidita
CEL_ZAD	celková zadluženost
DL_ZAD	dlouhodobá zadluženost
DO_AKT	doba obratu aktiv
DS_POH	doba splatnosti pohledávek
DÚ_KZ	doba úhrady krátkodobých závazků
EAT	čistý zisk
EBIT	zisk před úroky a zdaněním
EBT	zisk před zdaněním
FIN_PAK	finanční páka
OA_CA	podíl oběžných aktiv na celkových aktivech
OB_AKT	obrat aktiv
OK_LIK	okamžitá likvidita
ROA	rentabilita aktiv
ROCE	rentabilita dlouhodobých zdrojů
ROS	rentabilita tržeb
sk.	skupina
ÚR_ZAT	úrokové zatížení
VEL	velikost aktiv

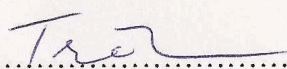
VK_CA podíl vlastního kapitálu na celkových aktivech

Prohlášení o využití výsledků diplomové práce

Prohlašuji, že

- jsem byl seznámen s tím, že na mou diplomovou práci se plně vztahuje zákon č. 121/2000 Sb. – autorský zákon, zejména § 35 – užití díla v rámci občanských a náboženských obřadů, v rámci školních představení a užití díla školního a § 60 – školní dílo;
- beru na vědomí, že Vysoká škola báňská – Technická univerzita Ostrava (dále jen VŠB-TUO) má právo nevýdělečně, ke své vnitřní potřebě, diplomovou práci užít (§ 35 odst. 3);
- souhlasím s tím, že diplomová práce bude v elektronické podobě archivována v Ústřední knihovně VŠB-TUO a jeden výtisk bude uložen u vedoucího diplomové práce. Souhlasím s tím, že bibliografické údaje o diplomové práci budou zveřejněny v informačním systému VŠB-TUO;
- bylo sjednáno, že s VŠB-TUO, v případě zájmu z její strany, uzavřu licenční smlouvu s oprávněním užít dílo v rozsahu § 12 odst. 4 autorského zákona;
- bylo sjednáno, že užít své dílo, diplomovou práci, nebo poskytnout licenci k jejímu využití mohu jen se souhlasem VŠB-TUO, která je oprávněna v takovém případě ode mne požadovat přiměřený příspěvek na úhradu nákladů, které byly VŠB-TUO na vytvoření díla vynaloženy (až do jejich skutečné výše).

V Ostravě dne 26. dubna 2013


.....
Bc. Aleš Trčka

Seznam příloh

Příloha 1 Testování multikolinearity

Příloha 2 Kroková metoda - krok 0 a 1

Příloha 3 Kroková metoda - krok 2 a 3

Příloha 4 Kroková metoda - krok 4 a 5

Příloha 5 Testování multikolinearity po vyřazení nevýznamných ukazatelů

Příloha 6 Výběr proměnných v jednotlivých krocích

Příloha 7 Charakteristika proměnných v jednotlivých krocích

Příloha 8 Výpočet poměru šancí

Příloha 9 Zpětné zařazení analyzovaného vzorku dat

Příloha 10 Vstupní data – Excel (CD)

Příloha 11 Diskriminační analýza – input PASW Statistics 18 (CD)

Příloha 12 Diskriminační analýza – output PASW Statistics 18 (CD)

Příloha 13 Diskriminační analýza – ověření predikční síly – Excel (CD)

Příloha 14 Logistická regrese – input PASW Statistics 18 (CD)

Příloha 15 Logistická regrese – output PASW Statistics 18 (CD)

Příloha 16 Logistická regrese – poměr šancí – Excel (CD)

Příloha 17 Logistická regrese – ověření predikční síly – Excel (CD)

Příloha 1 Testování multikolinearity

	Bankrot	ROA	ROCE	FIN_PAK	ROS	CEL_LIK	BEZ_LIK	OK_LIK	OB_AKT	DO_AKT	DS_POH	DÚ_KZ	VK_CA	OA_CA	CEL_ZAD	DL_ZAD	BE_ZAD	ÚR_ZAT	VEL
Bankrot	1	-.343	.094	-.182	-.175	-.090	-.077	-.034	-.092	.078	.045	.210	-.349	.192	.349	.231	.331	-.083	-.433
ROA	-.343	1	-.060	.147	.075	.048	.049	.048	-.074	.027	.017	-.025	.831	.056	-.830	-.543	-.849	.006	.438
ROCE	.094	-.060	1	-.045	.026	-.031	-.027	-.034	-.051	-.039	-.040	-.036	-.061	.102	.060	-.017	.075	.016	-.079
FIN_PAK	-.182	.147	-.045	1	-.030	.010	.011	.033	-.018	.088	.097	.163	.128	-.071	-.126	-.086	-.109	.015	.216
ROS	-.175	.075	.026	-.030	1	.026	.026	.032	.011	-.811	-.274	-.532	.064	.107	-.065	-.123	-.051	.046	.029
CEL_LIK	-.090	.048	-.031	.010	.026	1	.941	.532	-.003	.043	.070	-.034	.061	.077	-.060	-.014	-.072	.037	.014
BEZ_LIK	-.077	.049	-.027	.011	.026	.941	1	.594	.000	.051	.085	-.034	.060	.067	-.059	-.019	-.069	.023	.020
OK_LIK	-.034	.048	-.034	.033	.032	.532	.594	1	.000	.058	-.018	-.037	.057	.033	-.056	-.003	-.072	.015	-.061
OB_AKT	.092	-.074	-.051	-.018	.011	-.003	.000	.000	1	-.018	-.014	-.019	.000	-.006	.000	-.016	.005	.005	-.114
DO_AKT	.078	.027	-.039	.088	-.811	.043	.051	.058	-.018	1	.451	.547	.029	-.153	-.028	.026	-.035	-.031	.025
DS_POH	.045	.017	-.040	.097	-.274	.070	.085	-.018	-.014	.451	1	.407	.016	.030	-.016	.019	-.022	-.008	-.001
DÚ_KZ	.210	-.025	-.036	.163	-.532	-.034	-.034	-.037	-.019	.547	.407	1	-.127	-.081	.128	.191	.080	-.015	-.062
VK_CA	-.349	.831	-.061	.128	.064	.061	.060	.057	.000	.029	.016	-.127	1	.022	-1.000	-.708	-.974	.007	.443
OA_CA	.192	.056	.102	-.071	.107	.077	.067	.033	-.006	-.153	.030	-.081	.022	1	-.022	-.132	-.007	.009	-.212
CEL_ZAD	.349	-.830	.060	-.126	-.065	-.060	-.059	-.056	.000	-.028	-.016	.128	-1,000	-.022	1	.707	.976	-.007	-.442
DL_ZAD	.231	-.543	-.017	-.086	-.123	-.014	-.019	-.003	-.016	.026	.019	.191	-.708	-.132	.707	1	.582	-.011	-.293
BE_ZAD	.331	-.849	.075	-.109	.051	-.072	-.069	-.072	.005	-.035	-.022	.080	-.974	-.007	.976	.582	1	-.009	-.422
ÚR_ZAT	-.083	.006	.016	.015	.046	.037	.023	.015	.005	-.031	-.008	-.015	.007	.009	-.007	-.011	-.009	1	.009
VEL	-.433	.438	-.079	.216	.029	.014	.020	-.061	-.114	.025	-.001	-.062	.443	-.212	-.442	-.293	-.422	.009	1

Příloha 2 Kroková metoda - krok 0 a 1

Step	Ukazatel	Tolerance	Min. Tolerance	F to Enter	Wilks' Lambda	Step	Ukazatel	Tolerance	Min. Tolerance	F to Enter	Wilks' Lambda
0	ROA	1,000	1,000	42,992	,882	1	ROA	,883	,883	11,935	,783
	ROCE	1,000	1,000	2,895	,991		ROCE	,998	,998	1,447	,809
	FIN_PAK	1,000	1,000	11,066	,967		FIN_PAK	,976	,976	3,280	,804
	ROS	1,000	1,000	10,182	,969		ROS	,997	,997	10,783	,786
	CEL_LIK	1,000	1,000	2,609	,992		CEL_LIK	,999	,999	2,792	,805
	OK_LIK	1,000	1,000	,366	,999		OK_LIK	,993	,993	1,431	,809
	OB_AKT	1,000	1,000	2,764	,991		OB_AKT	,993	,993	,731	,811
	DS_POH	1,000	1,000	,655	,998		DS_POH	1,000	1,000	,793	,810
	DÚ_KZ	1,000	1,000	14,869	,956		DÚ_KZ	,999	,999	13,892	,779
	OA_NA_CA	1,000	1,000	12,280	,963		OA_NA_CA	,979	,979	4,177	,802
	DL_ZAD	1,000	1,000	18,073	,947		DL_ZAD	,951	,951	4,698	,801
	ÚR_ZAT	1,000	1,000	2,231	,993		ÚR_ZAT	,999	,999	2,475	,806
	VEL	1,000	1,000	74,376	,812						

Příloha 3 Kroková metoda - krok 2 a 3

Step	Ukazatel	Tolerance	Min. Tolerance	F to Enter	Wilks' Lambda	Step	Ukazatel	Tolerance	Min. Tolerance	F to Enter	Wilks' Lambda
2	ROA	,881	,881	12,498	,749	3	ROCE	,995	,881	1,709	,745
	ROCE	,995	,995	1,914	,774		FIN_PAK	,933	,867	5,838	,736
	FIN_PAK	,934	,934	6,663	,763		ROS	,731	,731	1,682	,745
	ROS	,734	,734	2,432	,773		CEL_LIK	,998	,881	2,075	,745
	CEL_LIK	,999	,998	2,491	,773		OK_LIK	,987	,874	,632	,748
	OK_LIK	,992	,992	1,137	,776		OB_AKT	,991	,878	,803	,748
	OB_AKT	,992	,992	,943	,776		DS_POH	,834	,833	,372	,749
	DS_POH	,834	,834	,447	,778		OA_NA_CA	,924	,845	10,126	,726
	OA_NA_CA	,964	,964	6,079	,764		DL_ZAD	,708	,674	,033	,749
	DL_ZAD	,927	,927	2,413	,773		ÚR_ZAT	,999	,881	2,467	,744
	ÚR_ZAT	,999	,998	2,402	,773						

Příloha 4 Kroková metoda - krok 4 a 5

Step	Ukazatel	Tolerance	Min. Tolerance	F to Enter	Wilks' Lambda	Step	Ukazatel	Tolerance	Min. Tolerance	F to Enter	Wilks' Lambda
4	ROCE	,989	,845	1,083	,724	5	ROCE	,989	,831	1,011	,711
	FIN_PAK	,933	,832	5,705	,714		ROS	,724	,697	1,885	,709
	ROS	,726	,726	2,315	,721		CEL_LIK	,990	,831	2,821	,707
	CEL_LIK	,990	,845	2,875	,720		OK_LIK	,985	,823	,492	,712
	OK_LIK	,987	,838	,666	,725		OB_AKT	,989	,826	1,091	,711
	OB_AKT	,990	,841	1,012	,724		DS_POH	,828	,787	,631	,712
	DS_POH	,829	,813	,735	,725		DL_ZAD	,696	,664	,020	,713
	DL_ZAD	,696	,664	,052	,726		ÚR_ZAT	,998	,831	2,553	,708
	ÚR_ZAT	,998	,845	2,642	,720						

Příloha 5 Testování multikolinearity po vyřazení nevýznamných ukazatelů

	Bankrot	ROA	FIN_PAK	ROS	DÚ_KZ	VK_NA_AKT	OA_CA	CEL_ZAD	DL_ZAD	BE_ZAD	VEL
Bankrot	1	-,343	-,182	-,175	,210	-,349	,192	,349	,231	,331	-,433
ROA	-,343	1	,147	,075	-,025	,831	,056	-,830	-,543	-,849	,438
FIN_PAK	-,182	,147	1	-,030	,163	,128	-,071	-,126	-,086	-,109	,216
ROS	-,175	,075	-,030	1	-,532	,064	,107	-,065	-,123	-,051	,029
DÚ_KZ	,210	-,025	,163	-,532	1	-,127	-,081	,128	,191	,080	-,062
VK_NA_AKT	-,349	,831	,128	,064	-,127	1	,022	-1,000	-,708	-,974	,443
OA_CA	,192	,056	-,071	,107	-,081	,022	1	-,022	-,132	-,007	-,212
CEL_ZAD	,349	-,830	-,126	-,065	,128	-1,000	-,022	1	,707	,976	-,442
DL_ZAD	,231	-,543	-,086	-,123	,191	-,708	-,132	,707	1	,582	-,293
BE_ZAD	,331	-,849	-,109	-,051	,080	-,974	-,007	,976	,582	1	-,422
VEL	-,433	,438	,216	,029	-,062	,443	-,212	-,442	-,293	-,422	1

Příloha 6 Výběr proměnných v jednotlivých krocích

			Score	df	Sig.				Score	df	Sig.
Step 0	Variables	FIN_PAK	10,765	1	,001	Step 3	Variables	FIN_PAK	,001	1	,975
		ROS	9,931	1	,002			ROS	11,101	1	,001
		DÚ_KZ	14,301	1	,000			DÚ_KZ	6,268	1	,012
		OA_NA_C A	11,903	1	,001			OA_NA_C A	1,385	1	,239
		CEL_ZAD	39,455	1	,000			CEL_ZAD	1,385	1	,239
		DL_ZAD	17,218	1	,000			DL_ZAD	6,775	1	,009
		VEL	60,796	1	,000			OA_NA_C A	4,216	1	,040
Step 1	Variables	FIN_PAK	2,358	1	,125	Step 4	Variables	FIN_PAK	,026	1	,873
		ROS	13,480	1	,000			DÚ_KZ	6,775	1	,009
		DÚ_KZ	13,515	1	,000			OA_NA_C A	4,216	1	,040
		OA_NA_C A	3,853	1	,050			Overall Statistics	13,260	3	,004
		CEL_ZAD	19,191	1	,000			FIN_PAK	,061	1	,805
		DL_ZAD	5,784	1	,016			OA_NA_C A	5,102	1	,024
		VEL	11,914	1	,001			Overall Statistics	5,136	2	,077
Step 2	Variables	FIN_PAK	,001	1	,977	Step 5	Variables	FIN_PAK	,061	1	,805
		ROS	6,343	1	,012			OA_NA_C A	5,102	1	,024
		DÚ_KZ	7,549	1	,006			Overall Statistics	5,136	2	,077
		OA_NA_C A	4,859	1	,028			FIN_PAK	,031	1	,860
		CEL_ZAD	19,191	1	,000			Overall Statistics	,031	1	,860
		DL_ZAD	5,784	1	,016						
		VEL	11,914	1	,001						
Step 3	Variables	FIN_PAK	,001	1	,977	Step 6	Variables	FIN_PAK	,031	1	,860
		ROS	6,343	1	,012			Overall Statistics	,031	1	,860
		DÚ_KZ	7,549	1	,006						
		OA_NA_C A	4,859	1	,028						
		CEL_ZAD	19,191	1	,000						
		DL_ZAD	5,784	1	,016						
		VEL	11,914	1	,001						

Příloha 7 Charakteristika proměnných v jednotlivých krocích

		B	S.E.	Wald	df	Sig.	Exp(B)			B	S.E.	Wald	df	Sig.	Exp(B)
Step 1	VEL	-,487	,069	50,333	1	,000	,614	Step 5	ROS	-1,644	,563	8,525	1	,004	,193
	Constant	4,187	,672	38,850	1	,000	65,823		DÚ_KZ	,000	,000	3,296	1	,069	1,000
Step 2	CEL_ZAD	2,014	,339	35,354	1	,000	7,490	Step 6	CEL_ZAD	2,816	,489	33,186	1	,000	16,711
	VEL	-,246	,078	9,989	1	,002	,782		DL_ZAD	-2,393	,611	15,343	1	,000	,091
Step 3	Constant	,225	,868	,067	1	,795	1,252		VEL	-,189	,083	5,179	1	,023	,828
	CEL_ZAD	2,858	,460	38,657	1	,000	17,426		Constant	-,513	,925	,308	1	,579	,598
Step 4	DL_ZAD	-1,952	,563	12,038	1	,001	,142		ROS	-1,999	,621	10,353	1	,001	,136
	VEL	-,221	,080	7,677	1	,006	,801		DÚ_KZ	,000	,000	3,246	1	,072	1,000
Step 5	Constant	-,121	,891	,019	1	,892	,886		OA_NA_CA	1,368	,613	4,978	1	,026	3,926
	ROS	-1,493	,556	7,221	1	,007	,225		CEL_ZAD	2,561	,495	26,825	1	,000	12,953
Step 6	CEL_ZAD	2,834	,485	34,125	1	,000	17,012		DL_ZAD	-2,043	,643	10,090	1	,001	,130
	DL_ZAD	-2,420	,607	15,876	1	,000	,089		VEL	-,149	,085	3,059	1	,080	,862
Step 7	VEL	-,200	,083	5,851	1	,016	,819		Constant	-1,727	1,083	2,541	1	,111	,178
	Constant	-,334	,914	,134	1	,715	,716								

Příloha 8 Výpočet poměru šancí

Velikost	VEL	
Hodnota 0		
P (CUR)	-1,727	0,151
P(Not CUR)	0,849	
P(C)/P(NC)	0,178	
Hodnota 1		
P (CUR)	-1,876	0,133
P(Not CUR)	0,867	
P(C)/P(NC)	0,153	
Δ ODDS	0,862	

Dlouhodobá zadluženost	DL_ZAD	
Hodnota 0		
P (CUR)	-1,727	0,151
P(Not CUR)	0,849	
P(C)/P(NC)	0,178	
Hodnota 1		
P (CUR)	-3,770	0,023
P(Not CUR)	0,977	
P(C)/P(NC)	0,023	
Δ ODDS	0,130	

Celková zadluženost	DL_ZAD	
Hodnota 0		
P (CUR)	-1,727	0,151
P(Not CUR)	0,849	
P(C)/P(NC)	0,178	
Hodnota 1		
P (CUR)	0,834	0,697
P(Not CUR)	0,303	
P(C)/P(NC)	2,303	
Δ ODDS	12,949	

Podíl oběžných aktiv na celkových aktivech	OA_CA	
Hodnota 0		
P (CUR)	-1,727	0,151
P(Not CUR)	0,849	
P(C)/P(NC)	0,178	
Hodnota 1		
P (CUR)	-0,359	0,411
P(Not CUR)	0,589	
P(C)/P(NC)	0,698	
Δ ODDS	3,927	

Doba úhrady krátkodobých závazků	DÚ_KZ	
Hodnota 0		
P (CUR)	-1,727	0,151
P(Not CUR)	0,849	
P(C)/P(NC)	0,178	
Hodnota 1		
P (CUR)	-1,727	0,151
P(Not CUR)	0,849	
P(C)/P(NC)	0,178	
Δ ODDS	1,000	

Rentabilita tržeb	ROS	
Hodnota 0		
P (CUR)	-1,727	0,151
P(Not CUR)	0,849	
P(C)/P(NC)	0,178	
Hodnota 1		
P (CUR)	-3,726	0,024
P(Not CUR)	0,976	
P(C)/P(NC)	0,024	
Δ ODDS	0,135	

Příloha 9 Zpětné zařazení analyzovaného vzorku dat

Pozorování			Predikce		
			Bankrot		Správnost
			0	1	
Step 1	Bankrot	0	183	26	87,6
		1	58	57	49,6
	Celkem				74,1
Step 2	Bankrot	0	197	12	94,3
		1	50	65	56,5
	Celkem				80,9
Step 3	Bankrot	0	193	16	92,3
		1	50	65	56,5
	Celkem				79,6
Step 4	Bankrot	0	195	14	93,3
		1	44	71	61,7
	Celkem				82,1
Step 5	Bankrot	0	194	15	92,8
		1	41	74	64,3
	Celkem				82,7
Step 6	Bankrot	0	194	15	92,8
		1	42	73	63,5
	Celkem				82,4